



DETECÇÃO E DIAGNÓSTICO DE FALHAS EM PLANTAS INDUSTRIAIS COM
BASE EM PADRÕES DE ALARMES

Vinícius Barroso Soares

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Química, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Química.

Orientadores: José Carlos Costa da Silva Pinto

Maurício Bezerra de Souza Júnior

Rio de Janeiro

Março de 2016

DETECÇÃO E DIAGNÓSTICO DE FALHAS EM PLANTAS INDUSTRIAIS COM
BASE EM PADRÕES DE ALARMES

Vinícius Barroso Soares

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM
CIÊNCIAS EM ENGENHARIA QUÍMICA.

Examinada por:

Prof. José Carlos Costa da Silva Pinto, D.Sc.

Prof. Maurício Bezerra de Souza Jr., D.Sc.

Prof. Príamo Albuquerque Melo Jr., D.Sc.

Prof. Márcia Peixoto Vega Domiciano, D.Sc.

Dr. Mario Cesar Mello Massa de Campos, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

MARÇO DE 2016

Soares, Vinícius Barroso

Detecção e Diagnóstico de Falhas em Plantas de Processos Químicos com Base em Padrões de Alarmes/ Vinícius Barroso Soares. – Rio de Janeiro: UFRJ/COPPE, 2016.

XX, 197 p.: il.; 29,7 cm.

Orientador: José Carlos Costa da Silva Pinto

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Química, 2016.

Referências Bibliográficas: p. 136-145.

1. Gerenciamento de Alarmes. 2. Análise Multivariada de Dados. 3. Detecção e Diagnóstico de Falhas. 4. Planta de Gás Natural. 5. Reatores Químicos. I. Pinto, José Carlos Costa da Silva *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Química. III. Título.

“Fala-se tanto da necessidade de deixar um planeta melhor para nossos filhos e esquece-se da urgência de deixarmos filhos melhores (educados, honestos, dignos, éticos, responsáveis) para o nosso planeta, através dos nossos exemplos”

Chico Xavier.

AGRADECIMENTOS

Agradeço primeiramente a Deus que permitiu o encaixe perfeito de todas as peças na hora exata. A Jesus Cristo, filho de Deus, pelos ensinamentos de amor e humildade que faz guiar toda a humanidade para o bem. Agradeço ao professor José Carlos Costa da Silva Pinto pela grande oportunidade dada para iniciar meu Doutorado na COPPE/UFRJ. Agradeço pelos seus ensinamentos acadêmicos, orientações e motivação para continuar seguindo em frente na constante busca pelo conhecimento. Agradeço ao professor Maurício Bezerra de Souza por sempre estar à disposição, respondendo minhas dúvidas e me incentivando a acreditar que tudo daria certo. Ao Programa de Engenharia Química da Universidade Federal do Rio de Janeiro, seus coordenadores, professores e funcionários, pela dedicação e oportunidade. Às sugestões da professora Márcia Peixoto Vega Domiciano e do consultor Mario Cesar Mello Massa de Campos ainda na etapa da qualificação desta tese. Os ensinamentos e direcionamento do professor Príamo Albuquerque Melo Junior durante as apresentações de seminário realizado junto ao PEQ/COPPE. Agradeço por terem entendido minhas limitações e incentivado a perseverar durante todo o grande desafio que representaria o doutoramento. Agradeço à minha esposa, Clarice Araújo Mattos Soares, por estar ao meu lado durante esse tempo de trabalho, e não medir esforços para me ajudar. Resgatou-me de momentos bastante difíceis, sempre com uma solução simples para os meus problemas que pareciam ser gigantes. Aos meus pais, Uilians Roberto Soares e Luciana Nazaré Barroso Soares, que sempre me apoiaram incondicionalmente e sempre estão torcendo pelas minhas conquistas. Ao meu irmão, Renan Barroso Soares, pela torcida. Agradeço aos meus familiares, por toda contribuição desde o meu nascimento e por entender em minha ausência em tantos momentos importantes. Aos meus amigos. Aos colegas de trabalho da área industrial, que fizeram parte desta experiência e de onde pude obter grande massa de conhecimento prático e teórico. A todos aqueles que, direta ou indiretamente, colaboraram no desenvolvimento desse estudo. Com todos vocês divido esta imensa alegria.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

DETECÇÃO E DIAGNÓSTICO DE FALHAS EM PLANTAS INDUSTRIAIS COM BASE EM PADRÕES DE ALARMES

Vinícius Barroso Soares

Março/2016

Orientadores: José Carlos Costa da Silva Pinto

Maurício Bezerra de Souza Jr.

Programa: Engenharia Química

Sistemas de alarmes bem configurados permitem melhorar a qualidade e segurança dos processos. Por outro lado, a má configuração provoca uma elevada taxa de ativação diária nas salas de controle, tornando o ambiente desfavorável para o operador. Neste trabalho é proposto um sistema de monitoramento de processos baseado nas ocorrências de alarmes. Duas situações são discutidas: i) padrões de alarmes estacionários com comportamento desconhecido e ii) padrões de alarmes dinâmicos com comportamento conhecido. Na primeira abordagem, buscou-se uma solução prática para alguns problemas comuns e relacionados ao excessivo número de alarmes. Os dados foram obtidos por meio de um estudo de caso real aplicado em uma Unidade de Tratamento de Gás Natural. As técnicas estatísticas utilizadas foram as análises de correlação, de componentes principais e de agrupamentos. Na segunda abordagem, buscou-se uma solução inovadora para diagnosticar falhas em função do tipo de padrão de alarme apresentado. A ideia central é a de que as diferentes falhas em uma planta industrial geram padrões de alarmes bem definidos. Portanto, uma vez mapeados estes padrões, fica mais simples interpretar os padrões de alarmes (binários e discretos) do que o comportamento das variáveis medidas do processo (contínuas e analógicas).

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

FAULT DETECTION AND DIAGNOSIS IN INDUSTRIAL PLANTS BASED ON
ALARM PATTERNS

Vinícius Barroso Soares

March/2016

Advisors: José Carlos Costa da Silva Pinto

Maurício Bezerra de Souza Jr.

Department: Chemical Engineering

Well-configured alarm systems allow for improvement of the quality and safety of industrial. On the other hand, badly-configured alarm systems cause high daily activation rates in the control room, making the working environment challenging for the operator. For this reason, the present thesis proposes the implementation of monitoring systems based on alarm events. Two situations were discussed: i) analyses of alarms patterns with unknown process behavior and; ii) analyses of dynamic alarms patterns with known process behavior. In the first approach, a practical solution is sought for some common problems in alarm systems, related to high alarm activity. Data were obtained through the real case study of a Natural Gas Treatment Unit. The statistical techniques used to evaluate the available information were correlation analyses, principal component analyses and cluster analyses. In the second approach, an innovative that is solution able to diagnose faults based on the type of alarm pattern displayed by the dynamic process is proposed. The main idea is that failures in an industrial plant generate well-defined dynamic alarms patterns. So, once these patterns are mapped, it becomes simpler to interpret the process behavior in terms of the data alarms (binary and discrete) than in terms of the process variables (continuous and analogue).

Sumário

1. INTRODUÇÃO	1
1.1. Aspectos Gerais	2
1.2. Motivações para o Trabalho	5
1.3. Objetivos.....	8
1.4. Organização do Texto.....	8
2. REVISÃO BIBLIOGRÁFICA	10
2.1. O Alarme Inserido no Contexto da Segurança de Processos	11
2.2. Principais Problemas em Sistemas de Alarmes	15
2.3. Indicadores de Desempenho	21
2.4. Análise de Correlação.....	27
2.5. Análise de Agrupamentos.....	38
2.6. Análise de Componentes Principais	44
2.7. Considerações Finais	48
3. ESTUDO DE CASO REAL	49
3.1. Metodologia Aplicada ao Estudo de Caso Real	50
3.2. Apresentação da Unidade	63
3.3. Análise Inicial do Sistema de Alarmes.....	68
3.4. Resultados Obtidos com a Implementação da Metodologia	70
3.5. Análise das Distribuições de Probabilidade dos Alarmes	77
3.6. Análise de Correlação dos Alarmes e das Variáveis do Processo	81
3.6.1. Caso 1: sistema do forno de óleo térmico	81
3.6.2. Caso 2: sistema de refrigeração a propano	94
3.7. Considerações Finais	105

4. ESTUDO DE CASO SIMULADO	107
4.1. Metodologia Aplicada ao Estudo de Caso Simulado	108
4.2. Modelo Proposto para Análise	110
4.3. Cenários de Falhas Testados.....	114
4.3.1. Eventos determinísticos: perturbações nas variáveis do processo.....	114
4.3.2. Eventos aleatórios: presença de ruído de medição	117
4.4. Análise dos Resultados.....	118
4.4.1. Análise dos alarmes na presença de perturbações no processo	118
4.4.2. Análise dos alarmes na presença de ruído de medição.....	127
4.5. Considerações Finais	131
5. CONCLUSÕES E SUGESTÕES	132
5.1. Conclusões.....	133
5.2. Sugestões para Trabalhos Futuros	134
REFERÊNCIAS BIBLIOGRÁFICAS	136
APÊNDICE	146
Apêndice 1. Dados Diários de Ativação de Alarmes na Planta.....	147
Apêndice 2. Código de Programação Implementado no MATLAB®	180

Lista de Figuras

Figura 1. Exemplo de camadas de proteção em planta industrial.	12
Figura 2. Possíveis localização da falha em uma planta industrial.	14
Figura 3. Exemplo de setpoint de alarme muito expansivo.....	20
Figura 4. Exemplo de setpoint de alarme muito conservador.	20
Figura 5. Exemplo de setpoint de alarme bem configurado.	21
Figura 6. Exemplo de comportamento dinâmica do sinal de alarme em uma planta industrial.....	25
Figura 7. Componentes de uma variável de processo.	27
Figura 8. Limites de confiança com curva normal.	32
Figura 9. Exemplo de janela deslizante para análise de correlação de alarmes.	36
Figura 10. Etapas envolvidas em uma análise típica de agrupamentos.....	39
Figura 11. Exemplo de dendograma horizontal.	40
Figura 12. Exemplo de dendograma horizontal.	41
Figura 13. Ciclo de gerenciamento de alarmes.....	51
Figura 14. Localização do protocolo de gerenciamento de alarmes.....	51
Figura 15. Fluxograma principal do protocolo de gerenciamento de alarmes.	53
Figura 16. Fluxograma da etapa 1 do protocolo de gerenciamento de alarmes.	55
Figura 17. Fluxograma da etapa 2 do protocolo de gerenciamento de alarmes.	57
Figura 18. Resultado obtido com a análise de frequência.	59
Figura 19. Resultado obtido com a análise de Pareto.....	61
Figura 20. Resultado obtido com análise de ocorrência.....	62
Figura 21. Visão simplificada da planta de processamento de gás natural.	67
Figura 22. Distribuição das ocorrências de alarmes digitais na planta durante todo o período analisado.....	72
Figura 23. Frequência de ativação com base nas ocorrências mensais em um ano.	74
Figura 24. Frequência de ativação em um certo mês ao longo de três anos.....	75
Figura 25. Comportamento da curva binomial para as ativações de alarmes na planta dado o número total de ocorrências registrado no período de três anos.....	78
Figura 26. Distribuição normal de probabilidades das ativações mensais dos alarmes em três anos de análise.	79

Figura 27. Distribuição exponencial de probabilidades das ativações mensais dos alarmes em três anos de análise.	79
Figura 28. Distribuição gama de probabilidades das ativações mensais dos alarmes em três anos de análise.	80
Figura 29. Distribuição log-normal de probabilidades das ativações mensais dos alarmes em três anos de análise.	80
Figura 30. Simplificação do sistema do forno de óleo térmico com indicação das variáveis de processo utilizadas para monitoramento operacional.	83
Figura 31. Comportamento das pressões na seção de óleo térmico.	84
Figura 32. Comportamento das temperaturas na seção de óleo térmico.	85
Figura 33. Comportamento das vazões na seção de óleo térmico.	85
Figura 34. Mapa de cores das variáveis do processo do sistema do forno de óleo.	87
Figura 35. Mapa de cores dos alarmes do sistema do forno de óleo térmico com valores de setpoint originais.	87
Figura 36. Mapa de cores dos alarmes do sistema do forno de óleo térmico para valores de setpoint definidos com base na estatística descritiva.	88
Figura 37. Distribuições das variáveis do processo padronizadas e ajuste normal.	89
Figura 38. Dendograma obtido a partir das variáveis do processo da seção de óleo térmico utilizando a distância Euclidiana.	90
Figura 39. Dendograma obtido a partir das variáveis do processo da seção de óleo térmico utilizando a distância da correlação inversa.	90
Figura 40. Dendograma obtido a partir dos alarmes da seção de óleo térmico utilizando a distância Euclidiana.	91
Figura 41. Dendograma obtido a partir dos alarmes da seção de óleo térmico utilizando a distância da correlação inversa.	92
Figura 42. Análise das componentes principais das variáveis do processo da seção do forno de óleo térmico.	93
Figura 43. Análise de componentes principais das ocorrências de alarmes da seção do forno de óleo térmico.	93
Figura 44. Fluxograma simplificado do sistema de refrigeração a propano.	95
Figura 45. Mapa de cores das variáveis de processo do sistema de refrigeração a propano em período caracterizado como operação normal da planta.	98
Figura 46. Mapa de cores dos alarmes do sistema de refrigeração a propano em período caracterizado como operação normal da planta.	98

Figura 47. Relação entre as variáveis de processo Var20 e Var5 e o alarme tag5 do sistema de refrigeração a propano.	99
Figura 48. Mapa de cores das variáveis de processo do sistema de refrigeração a propano na parada do compressor de propano.	100
Figura 49. Mapa de cores dos alarmes do sistema de refrigeração a propano na parada do compressor de propano.	100
Figura 50. Relação entre as variáveis de processo Var1 e Var5 e os alarmes tag1 e tag5 do sistema de refrigeração a propano.	101
Figura 51. Mapa de cores das variáveis de processo do sistema de refrigeração a propano na parada da planta.	102
Figura 52. Mapa de cores dos alarmes do sistema de refrigeração a propano na parada da planta.	102
Figura 53. Relação entre as variáveis de processo Var9, Var10 e Var14 e os alarmes tag9, tag10 e tag14 do sistema de refrigeração a propano.	103
Figura 54. Mapa de cores das variáveis de processo do sistema de refrigeração a propano para oscilações na malha de controle.	104
Figura 55. Mapa de cores dos alarmes do sistema de refrigeração a propano para oscilações na malha de controle.	104
Figura 56. Visão geral das etapas da metodologia aplicada ao estudo de caso simulado.	109
Figura 57. Reator contínuo de tanque agitado.	110
Figura 58. Comportamento do reator em condição normal de operação.	113
Figura 59. Comportamento do reator na presença de oscilações sustentadas em T_c	113
Figura 60. Variações de T em função de variações de q.	115
Figura 61. Variações de C_A em função de variações de q.	115
Figura 62. Variações de T em função de variações de q_c	116
Figura 63. Variações de C_A em função de variações de q_c	116
Figura 64. Histograma dos ruídos aleatórios padronizados.	117
Figura 65. Presença de ruído de medição associado a variável T_c	118
Figura 66. Frequência observada das ocorrências do alarme de temperatura alta do reator para vários valores de setpoint e para variações em q.	121
Figura 67. Frequência observada das ocorrências do alarme de concentração baixa do reator para vários valores de setpoint e para variações em q.	121

Figura 68. Modelo de predição do alarme de temperatura alta do reator para setpoint do alarme fixo e q_c variável.	122
Figura 69. Modelo de predição do alarme de concentração baixa do reator para setpoint do alarme fixo e q_c variável.	123
Figura 70. Influência do ruído de medição nas correlações (a) sem presença de ruído e (b) com presença de ruído.	128
Figura 71. Algoritmo implementado em VBA-Excel® para identificar a presença de alarmes ruidosos na presença de setpoint de 346,50 K.	129
Figura 72. Algoritmo implementado em VBA-Excel® para identificar a presença de alarmes ruidosos na presença de setpoint de 352 K.	129
Figura 73. Comportamento dinâmico do sinal do alarme (a) e tempo de duração entre ativações de alarmes subsequentes (b) na presença de setpoint de 346,50 K.	130
Figura 74. Comportamento dinâmico do sinal do alarme (a) e tempo de duração entre ativações de alarmes subsequentes (b) na presença de setpoint de 352 K.	130

Lista de Tabelas

Tabela 1. Configuração dos níveis de prioridade dos alarmes.	16
Tabela 2. Métricas de desempenho para monitoramento de sistemas de alarmes.....	22
Tabela 3. Valores sugeridos para configuração de banda morta.	23
Tabela 4. Valores sugeridos para configuração de tempo de atraso.....	24
Tabela 5. Valores sugeridos para configuração de filtro temporizador.....	24
Tabela 6. Estrutura necessária para a realização da análise de frequência.....	58
Tabela 7. Estrutura para a realização da análise de Pareto.....	60
Tabela 8. Estrutura para a realização da análise de ocorrência.	62
Tabela 9. Distribuição dos alarmes digitais configurados na planta.	69
Tabela 10. Diferenças entre os níveis de prioridade dos alarmes da planta.	70
Tabela 11. Distribuição das ocorrências de alarmes na planta.	71
Tabela 12. Frequência das ocorrências mensais dos alarmes em um ano.	73
Tabela 13. Frequência das ocorrências dos alarmes em um mesmo mês em três anos de análises contínuas.	75
Tabela 14. Probabilidade de causas iniciadoras de eventos determinísticos.....	76
Tabela 15. Proposta para identificação de alarmes relacionados.	81
Tabela 16. Matriz de correlação para identificar alarmes correlacionados.	82
Tabela 17. Matriz de autocorrelação do alarme PAH052.	82
Tabela 18. Valores originais dos setpoints de alarmes configurados no sistema do forno de óleo térmico.	84
Tabela 19. Resumo estatístico do comportamento das variáveis do processo do sistema do forno de óleo térmico.....	86
Tabela 20. Variáveis mais importantes para monitoramento operacional do sistema de refrigeração a propano.	96
Tabela 21. Valores originais dos setpoints de alarmes configurados no sistema de refrigeração a propano.	96
Tabela 22. Valores médios das variáveis de processo em operação normal no sistema de refrigeração a propano.	97
Tabela 23. Parâmetros fixos do modelo.	112
Tabela 24. Momento da ativação do alarme de temperatura alta do reator em função do setpoint configurado e da vazão de alimentação do reator.....	119

Tabela 25. Momento da ativação do alarme de concentração baixa no reator em função do setpoint configurado e da vazão de alimentação do reator.	120
Tabela 26. Valores dos setpoints de alarmes configurados no reator.....	123
Tabela 27. Possibilidades de padrões de alarmes diferentes no processo.	124
Tabela 28. Frequência de ocorrência dos alarmes para diferentes q	125
Tabela 29. Padrões de alarmes observados para perturbações em q	125
Tabela 30. Frequência de ocorrência dos alarmes para diferentes q_c	126
Tabela 31. Padrões de alarmes observados para perturbações em q_c	126
Tabela 32. Dados diários das ocorrências de alarmes na planta registrados durante o período de três anos.	147

Lista de Siglas

- AIT – Transmissor Indicador de Concentração.
- ANP – Agência Nacional do Petróleo, Gás Natural e Biocombustíveis.
- API – *American Petroleum Institute*. Instituto Americano do Petróleo.
- APR – Análise Preliminar de Riscos.
- ASM – *Abnormal Situations Management*. Gerenciamento de Situações Anormais.
- CSTR – *Continous Stirred Tank Reactor*. Reator Contínuo Perfeitamente Agitado.
- EEMUA – *Engineering Equipment and Materials Users' Association*. Equipamentos de Engenharia e a Associação de Usuários de Materiais.
- EPE – Empresa de Pesquisas Energéticas.
- EPI – Equipamos de Proteção Individual.
- EPRI – *Electric Power Research Institute*. Instituto de Pesquisas de Energia Elétrica.
- ESD – *Emergency Shutdown System*. Sistema de Desligamento de Emergência.
- FDDC – *Fault Detection, Diagnosis and Correction*. Detecção, Diagnostico e Correção de Falhas.
- FIT – Transmissor Indicador de Vazão.
- GE – Gás Especificado.
- GLP – Gás Liquefeito de Petróleo.
- GN – Gás Natural.
- GUM – *Guide to the Expression of Uncertainty in Measurement*. Guia para a Expressão da Incerteza de Medição.
- HI – *High*. Alto.
- HIHI – *High-High*. Alto-Alto.
- HSE – *Health & Safety Executive*. Executivo de Saúde e Segurança.
- IEC – *International Electrotechnical Commission*. Comissão Internacional de Eletrotécnica.
- IHM – Interface-Homem-Máquina.
- ISA – *International Society of Automation*. Sociedade Internacional de Automação.
- LGN – Líquido de Gás Natural.
- LIC – Limite Inferior de Controle.
- LIT – Transmissor Indicador de Nível.
- LO – *Low*. Baixo.

LOLO – *Low-Low*. Baixo-Baixo.

MATLAB – *Matrix Laboratory*. Laboratório de Matriz.

NAMUR – *User Association of Process Control Technology in Chemical Pharmaceutical Industries*. Associação de Usuários da Tecnologia de Controle de Processos em Indústrias Químicas Farmacêuticas.

NRC – *Nuclear Regulatory Commission*. Comissão Regulatória Nuclear.

PC – *Personal Computer*. Computador Pessoal.

PCA – *Principal Component Analysis*. Análise de Componentes Principais.

PDIT – Transmissor Indicador de Diferencial de Pressão.

PIMS – *Plant Information Management System*. Sistema de Gerenciamento de Informações da Planta.

PIT – Transmissor Indicador de Pressão.

PLC – *Programmable Logic Controller*. Controlador Lógico Programável.

PSV – *Pressure Safety Valve*. Válvula de Segurança e Pressão.

SCADA – *Supervisory Control and Data Acquisition*. Controle Supervisório e Aquisição de Dados.

SIS – Sistema Instrumentado de Segurança.

SSMA – Segurança, Saúde, Meio Ambiente.

TE – Turbo-Expansão.

TIT – Transmissor Indicador de Temperatura.

UFL – Unidade de Fracionamento de Líquidos.

UPCGN – Unidade de Processamento de Condensado de Gás Natural.

UPGN – Unidade de Processamento de Gás Natural.

VBA – *Visual Basic for Applications*. Aplicação Básica Visual.

VIT – Transmissor Indicador de Vibração.

Nomenclatura

$C_{k,n}$ – Combinação de k padrões dado n número de pontos.

C_k – Autocorrelação do evento k .

C_v – Coeficiente de variação.

$\mathbf{d}(\mathbf{X}_i, \mathbf{X}_k)$ – Medida de distância entre os pontos X_i e X_k .

f_i – Frequência de ocorrência do evento i .

F_α – Percentil da distribuição F com n_t e $n_k - n_t$ graus de liberdade.

n_k – Observações para compor e gerar o modelo.

N_T – Número total de experimentos realizados.

n_t – Número de componentes escolhidos.

$P_{\text{ativ.}}$ – Probabilidade de ativação do alarme i .

p_i – Probabilidade do evento i ocorrer.

Bin – Função binomial de probabilidades.

\mathbf{C} – Matriz de componentes principais.

C_{A0} – Concentração inicial da corrente de alimentação do reator.

C_A – Concentração no reator.

C_{ij} – Elemento ij da matriz de componentes principais.

C_p – Calor específico do meio reacional.

C_{pc} – Calor específico do fluido de refrigeração.

E – Energia de ativação.

K_0 – Constante da taxa de reação.

K_1 – Constante de Arrhenius da taxa de reação.

m_i – Número de repetições do evento i .

n_i – Número de sucessos do evento i .

$P(\text{DF})$ – Probabilidade de ocorrer a falha F com magnitude DF .

$P(F)$ – Probabilidade de ocorrer a falha F .

$P(i)$ – Probabilidade de ativação do alarme i dado seu histórico de ocorrência.

p_i – Probabilidade do evento i não ocorrer.

q – Vazão de alimentação do reator.

q_c – Vazão da corrente do fluido refrigerante.

q_i – Probabilidade do evento i ocorrer.

R – Constante dos gases ideias.
S – Estimativa para o vetor de covariância.
T – Temperatura do reator.
T₀ – Temperatura inicial da corrente de alimentação do reator.
T² – Estatística T² de Hotelling.
T_{c0} – Temperatura inicial do fluido refrigerante.
UA – Coeficiente de troca térmica.
V – Volume do reator.
Var – Variáveis analisadas.

Símbolos Gregos

σ^2_{xx} – Variância dos resultados de x.

σ^2_{XY} – Covariância entre os eventos X e Y.

X_i – Dado experimental i.

\bar{X} – Estimativa para o vetor das médias.

Z_i – Variáveis normalizadas adimensionais.

μ_i – Média aritmética dos eventos i.

ρ_{XY} – Correlação entre os eventos X e Y.

σ_x – Desvio-Padrão dos resultados de x.

α – Tolerância.

ΔH – Entalpia da reação.

λ_i – Autovetor corresponde ao i-ésimo componente principal.

ρ – Densidade do meio reacional.

ρ_c – Densidade do fluido refrigerante.

$D(t)$ – Curva Gaussiana ou curva de distribuição normal da variável contínua t.

1. INTRODUÇÃO

1.1. Aspectos Gerais

Em uma planta industrial, os alarmes são sinais que anunciam para o operador da sala de controle uma condição de mau funcionamento de equipamento, desvio de processo ou condição anormal que requer ação de resposta (ISA, 2009; ARJOMANDI e SALAHSHOOR, 2011; EEMUA, 2013). De acordo com Venkatasubramanian *et al.* (2003a), a maioria das tarefas de supervisão nas indústrias se baseia na simples verificação dos limites operacionais com auxílio de alarmes. Bransby (2000) e Bristol (2001) destacam que os alarmes são extremamente importantes para a segurança e eficiência das operações de plantas industriais modernas, como refinarias de petróleo, instalações petroquímicas e usinas de energia.

Pariyani (2010) apontou que os alarmes são ferramentas utilizadas para detectar os quase-acidentes, definidos como aquelas situações em que as variáveis de processo saem e subsequentemente retornam para as faixas normais de operação. Para Wang *et al.* (2015), os alarmes são as salvaguardas para evitar a evolução dos quase-acidentes para acidentes. Além disso, desempenham um papel importante na manutenção da eficiência da operação da planta, pois é fato bem conhecido que o desvio das variáveis de processo das condições normais/ótimas de operação geralmente implica em efeitos negativos, como produtos fora de especificação e consumo excessivo de matérias-primas e energia.

Mas, se por um lado os sistemas de alarme com desempenho satisfatório são capazes de ajudar os operadores a reduzir a duração e a probabilidade dos desvios, por outro lado os sistemas de alarme existentes nas plantas industriais sofrem com o fraco desempenho, mais notavelmente traduzido em sobrecargas de alarmes (WANG *et al.*, 2015). De acordo com Rothenberg e Wilson (2003), a maioria das indústrias não está preparada para lidar com o elevado volume de dados de alarmes gerados durante a operação normal e, principalmente, em situações de transição da planta, como paradas e partidas de unidades e/ou equipamentos.

Para Li *et al.* (2015), a expansão da quantidade de instrumentação presente nos sistemas de controle de processo das plantas industriais, juntamente com a crescente sofisticação dos sistemas computacionais, ocasionou a elevação do número de alarmes configurados nestas unidades. Como resultado, as empresas precisam investir mais para armazenar milhões de dados de alarmes gerados a cada ano. Além disso, transformar esse grande volume de dados em informação útil à tomada de decisão se tornou um dos grandes desafios da atualidade.

Para Izadi *et al.* (2009 a/b/c), o cenário ideal em uma planta industrial seria a existência de um único alarme para cada tipo de falha. Porém, em função das complexidades envolvidas nos processos, esta não é uma decisão trivial. Conforme apontado por Chang, Khan e Ahmed (2011), na maioria das vezes prefere-se pecar pelo excesso do que pela falta de monitoramento. Porém, este comportamento contribui para elevar o número de ocorrências de alarmes nas plantas, sobrecarregando os operadores de informações, muitas vezes irrelevantes. Para se ter uma dimensão do tamanho do problema, White (2003) destaca que um único operador é responsável pelo monitoramento de até 3.500 alarmes em uma planta industrial.

Pariyani *et al.* (2011) mencionam 10.000 ativações de alarmes por mês. O'Brien *et al.* (2004) citam 14.000 ativações em um único dia. Grosdidier *et al.* (2003) relatam 26.650 ocorrências de alarmes por dia, a uma taxa média de 14250 ativações por dia, o que significa mais de 5.000.000 alarmes por ano. Humanamente é impossível gerir todos estes sinais a contento. Um estudo conduzido pelo *Health and Safety Executive* (HSE, 1997), feito com 96 operadores de 13 plantas industriais, mostrou que, sob operação normal, um operador recebe, em média, um alarme a cada dois minutos. Porém, após um grande distúrbio na planta, este número passa para aproximadamente 90 alarmes no primeiro minuto e 70 alarmes nos 10 minutos subsequentes. Cerca de 50% dos operadores admitiram que se sentiram forçados a aceitar um alarme sem sequer avaliar o cenário.

Larsson (2000) destaca que grande parte do problema do excesso da ativação de alarmes nas plantas industriais está associado aos alarmes incômodos (*nuisance alarm*) e aos alarmes intermitentes (*chattering alarm*). Estes alarmes são aqueles que ocorrem na maioria das vezes pela falta de manutenção no sistema de alarmes, especialmente pela falha na concepção dos limites de atuação (*setpoint*) dos alarmes. Conforme EEMUA (2013), alarmes ruidosos são aqueles que anunciam excessivamente, desnecessariamente, ou que não retornam para à condição normal mesmo após ação do operador. Enquanto que, alarmes intermitentes são aqueles que transitam entre o estado ativado e o estado não ativado num curto período de tempo.

A presença de alarmes ruidosos reduz o tempo de resposta do operador frente aos alarmes reais. Dunn e Sands (2005) destacam o problema dos alarmes que permanecem muito tempo ativados no processo. São alarmes problemáticos, que acabam inundando as telas da operação e que acabem mascarando outros alarmes importantes para o operador. Normalmente, estes alarmes estão associados a equipamentos em manutenção, ou a

alarmes mal equalizados que, mesmo diante da normalização da variável de processo, permanecem em estado ativado.

Sabe-se que, em uma planta industrial, as várias etapas do processo estão interligadas entre si, o que significa que uma determinada falha ocorrida em uma parte do processo pode ser propagada para as demais, ocasionando diversas ativações de alarmes. Este efeito é conhecido como avalanche de alarmes (WANG *et al.*, 2015). Em tese, todas estas ocorrências de alarmes deveriam estar correlacionadas entre si, pois possuem a mesma causa raiz. Avalanches de alarmes sobrecarregam os operadores com uma quantidade de ativações muito superior à capacidade de diagnóstico, tornando bastante difícil a tarefa de determinar a causa da anormalidade.

Conforme discutido por Chiang *et al.* (2001), a busca por alternativas para o desenvolvimento de ferramentas capazes de auxiliar os operadores das plantas industriais em situações que envolvem tomadas de decisão mais rápidas e acertadas resultou em uma nova área do conhecimento conhecida por detecção, diagnóstico e correção de falhas (do inglês, *fault detection, diagnosis and correction* – FDDC). A área de FDDC conta com importantes revisões na literatura, como apresentado por Willsky (1976), Frank (1996), Isermann (1997), Venkatasubramanian *et al.* (2003a, b, c), Sartori *et al.* (2012), entre outros.

De acordo com Larsson e Joseph (2007), a diversidade de problemas que podem ocorrer nos sistemas de alarmes, somada à aparente falta de uma metodologia capaz de resolvê-los de forma simultânea e comercialmente viável, favorece o desenvolvimento de pesquisas, tanto na área acadêmica, quanto na área industrial. Nos últimos anos, diversos guias de recomendações práticas, baseados na experiência de vários usuários finais, foram desenvolvidos para auxiliar no projeto, gerenciamento e aquisição de sistemas de alarme na área industrial (WANG *et al.*, 2015). Neste cenário, a *Nuclear Regulatory Commission* dos Estados Unidos publicou o documento NUREG/CR-61056684 para dar orientação e base técnica para sistemas de alarme avançados (NRC, 2000). A *Engineering Equipment and Materials Users' Association* apresentou a diretriz EEMUA-191 para a concepção, gestão e aquisição de sistemas de alarme (EEMUA, 2013).

A *User Association of Process Control Technology in Chemical Pharmaceutical Industries* emitiu a norma NAMUR-NA-102 para o gerenciamento de alarme (NAMUR, 2003). O *Electric Power Research Institute* produziu o documento EPRI-1010076 com os requisitos e orientação para implementação de sistemas de alarme avançados (EPRI, 2005). A *Abnormal Situations Management Consortium* propôs um conjunto de diretrizes

para a prática de gerenciamento de alarme eficaz (ASM, 2009). A *International Society of Automation* e a *International Electrotechnical Commission* emitiram, respectivamente, as normas ANSI/ISA-18.2 (ISA, 2009) e IEC-68682 (IEC, 2014), para a gestão de sistemas de alarme nas indústrias de processo. O *American Petroleum Institute* publicou a norma API-1167 para gerenciamento de sistema supervisorio de controle e aquisição de dados (do inglês, *supervisory control and data acquisition – SCADA*), oleodutos e gerenciamento de alarme (API, 2010).

1.2. Motivações para o Trabalho

De modo geral, as indústrias têm sido palco de acidentes causadores de grandes devastações e prejuízos. Muitas delas ainda encobrem os verdadeiros fatos, fazendo com que os mesmos problemas perdurem. Segundo Khan e Abbasi (1999), 25% dos acidentes ocorridos nas indústrias químicas estão associados a explosões ou incêndios e 71% envolvem liberações de gases tóxicos na atmosfera, principalmente amônia e hidrocarbonetos. As causas gerais mais frequentes dos acidentes são as falhas em equipamentos (29%), falhas operacionais (21%), cálculos inadequados de material (16%), problemas no processo (11%) e problemas na mecânica dos materiais (9%). Os acidentes apresentados, a seguir, fornecem uma ideia das dimensões de tais eventos e destacam a importância dos sistemas de alarmes numa planta industrial. Estas informações podem ser usadas como justificativa para investimentos em gerenciamento de alarme e também servem para aumentar a conscientização sobre a importância do tema.

- *Three Mile Island*, 1979

O acidente que ocorreu na central nuclear de Three Mile Island em 1979 e os danos causados à planta resultaram no seu fechamento. As perdas financeiras foram estimadas em US\$ 1 bilhão. Não houve mortes ou ferimentos graves como resultado direto do acidente, mas houve liberação de material radioativo no meio ambiente. Várias causas contribuíram para o acidente, mas ficou claro que se os operadores tivessem o entendimento total do que estava acontecendo, provavelmente eles teriam sido capazes de impedir o ocorrido. Havia uma série de deficiências na interface entre os sistemas de alarmes e o operador, sendo que um desses problemas era a sobrecarga de informação que os operadores recebiam do sistema de alarmes (RUBINSTEIN e MASON, 1979).

- *Milford Haven Refinery, 1994*

A explosão e os incêndios na Refinaria Texaco, *Milford Haven*, no Reino Unido em 1994, resultou em danos estimados em £ 48.000.000 associados à perda de produção e multa de £ 200.000. Ao todo foram registrados 26 ferimentos leves, mas nenhuma grave lesão ou fatalidades. O acidente foi causado por falha de equipamento, juntamente com má concepção de uma modificação. De acordo com entrevistas, os operadores da usina teriam tempo suficiente para reconhecer e evitar o acidente se não fossem prejudicados pela falta de gestão dos sistemas de alarmes e pela má visualização das telas e gráficos dos seus monitores. Durante o evento, alarmes eram apresentados a uma taxa de um a cada 2 – 3 segundos nas 5 horas que antecederam o acidente. Havia 275 alarmes nos 10,7 minutos antes da explosão (HSE, 1997; POWELL-PRICE, 1997).

- *Channel Tunnel Fire, 1996*

O incêndio ocorrido no Canal do Túnel, em novembro de 1996, resultou em prejuízos estimados em quase £ 200 milhões, incluindo danos e perdas na receita operacional. Alguns passageiros sofreram lesões graves em função da fumaça. Segundo a investigação, um dos fatores que contribuiu para o ocorrido foi a prática de ignorar alarme em função da quantidade de falsos alarmes que eram diariamente anunciados. A consequência disto foi que o sistema de detecção de incêndio reagiu, mas não teve o devido crédito. Além disso, durante os primeiros minutos do acidente, os operadores do Centro de Controle Ferroviário foram submetidos a uma sobrecarga de informações de alarmes. Uma das recomendações do relatório do acidente foi a necessidade de implantação de um sistema de gerenciamento de alarmes (EEMUA, 2013).

Outros acidentes deste porte foram descritos por Venkatasubramanian *et al.* (2003a), Bisarya e Puri (2005) e Abdolhamidzadeh *et al.* (2010). Parece claro que estes tipos de acidentes não devem ter mais espaço nas plantas industriais, de maneira que políticas devem ser estabelecidas para eliminar qualquer tipo de situação que possa causar estes eventos. No entanto, existem situações menos agressivas, mas que também causam sérios problemas financeiros nas indústrias: os desvios de operação.

De acordo com Bransby *et al.* (1998), as indústrias petroquímicas norte-americanas gastam, em média, US\$ 20 bilhões por ano em função de distúrbios que ocorrem nas plantas por motivos diversos. Apesar disso, a intervenção no processo para corrigir eventuais desvios, embora desejada, não deve ser feita de forma exagerada.

Primeiro, porque toda vez que se perturba o processo são introduzidos transientes ou efeitos de longo prazo que podem obrigar o operador a perturbar o processo novamente no futuro. Segundo, porque a modificação frequente das condições de operação acelera o envelhecimento de válvulas e demais equipamentos, aumentando os custos de produção. Terceiro, porque não se deve esquecer que as medidas aferidas pela instrumentação de campo contêm erros e, por isto, muitas vezes o operador pode ser induzido a corrigir desvios que de fato não existem, introduzindo alterações aleatórias e complexas na cadeia de produção.

A retrospectiva apresentada apoia o importante papel desempenhado pelos sistemas de alarme. Os alarmes surgem como uma alternativa atraente capaz de fornecer aos operadores as informações necessárias para que uma ação de correção seja realizada na planta, corrigindo um desvio de operação em tempo oportuno. No entanto, diante dos problemas que normalmente se fazem presentes na maioria dos sistemas de alarmes das plantas industriais, uma pergunta pertinente que poderia ser feita é: como é possível agregar valor aos sistemas de alarmes? Em outras palavras, como é possível eliminar dos sistemas de alarmes aqueles sinais que não estão associados a nenhum desvio no processo? Estes alarmes deveriam existir? Estas questões foram aprofundadas em um estudo de caso real aplicado numa Unidade de Processamento de Gás Natural (UPGN).

De acordo com Vaz *et al.* (2008), Unidades de Tratamento de Gás Natural são plantas de processamento que envolvem condições elevadas de pressão, muitas vezes acima de 9.000 kPa e temperaturas extremas, que podem variar de -70 °C a 300 °C. Estas unidades geralmente contam com equipamentos robustos (vasos, tanques, torres de destilação, compressores, bombas *etc.*), capazes de processar, transportar e armazenar quantidades significativas de materiais. Os produtos manuseados e seus derivados são em sua grande maioria inflamáveis e explosíveis, o que requer extrema atenção com as condições do processo, principalmente porque o processo é dinâmico e pode mudar drasticamente em função da composição da carga processada. Além disso, UPGNs costumam ser os “gargalos” dos campos de produção/exploração, de maneira que a parada de uma UTGC pode significar a interrupção total das atividades desses campos, seja ela no mar (*offshore*) ou na terra (*onshore*).

Para exemplificar este problema, Andrade (2012) descreveu os custos envolvidos com a parada de uma planta que, conforme relatórios de operação, leva de uma a quatro horas. Considerando uma produção de gás especificado de 2,5 milhões de m³ por dia, com produção de líquido de gás natural (LGN) de, aproximadamente, 450 m³ por dia, e preços

de venda de US\$ 0,21988/m³ para o gás industrial e US\$ 428,25/m³ para o LGN, o lucro cessante é de US\$ 671,09/hora. Ou seja, a empresa perde este montante por hora, quando a planta está fora de operação. Esta estimativa não inclui as perdas decorrentes do tempo de partida da unidade, necessário para que a planta retorne ao estado estacionário. Durante este período de regime transiente, o LGN não é totalmente extraído da corrente de gás, sendo enviado com o gás para a companhia distribuidora local a preço muito inferior ao padrão de operação normal. Sob o ponto de vista da cadeia de produção do gás natural, paradas acima de duas horas implicam em redirecionamento de parte do gás natural para outras unidades de processamento e manobras para o fechamento de poços de produção, pois as outras unidades não conseguem acomodar toda a produção da unidade analisada. Desta forma, este cenário também afeta o mercado consumidor, na maioria constituído por indústrias que precisam ser avisadas sobre um possível racionamento temporário.

1.3. Objetivos

O objetivo principal deste trabalho foi propor um sistema de detecção e diagnóstico de falhas em plantas de processos químicos com base nas ocorrências de alarmes. Os resultados foram discutidos sob duas perspectivas diferentes. Na primeira abordagem buscou-se desenvolver um protocolo de gerenciamento de alarmes capaz de reduzir o número excessivo de ocorrências de alarmes, bem como sugerir simplificações nestes sistemas com base na análise do comportamento conjunto das variáveis do processo. Os dados foram obtidos a partir de um estudo de caso real aplicado em uma Unidade de Tratamento de Gás Natural. As ferramentas estatísticas utilizadas foram as análises de frequência, Pareto, ocorrência, correlação, agrupamentos e componentes principais. Na segunda abordagem buscou-se avaliar a formação dos padrões de alarmes na presença de perturbações específicas. Os dados foram obtidos por meio de simulações com uso do modelo de um reator contínuo do tipo tanque agitado (*continuous stirred tank reactor* – CSTR) com reação exotérmica. A ideia central é provar que padrões de alarmes podem ser relacionados a eventos determinístico e, a partir deste mapeamento, é possível diagnosticar falhas ocorridas no processo observado apenas os padrões de alarmes.

1.4. Organização do Texto

Este trabalho está estruturado em cinco capítulos incluindo esta Introdução. No Capítulo 2 (Revisão Bibliográfica), são apresentados os termos e definições comuns à área de gerenciamento de alarmes, os principais problemas enfrentados nas plantas

industriais, os indicadores de desempenho mais utilizados, bem como as técnicas consideradas como de alto desempenho para identificação e solução de problemas em sistemas de alarmes. No Capítulo 3 (Estudo de Caso Real), é apresentada a Unidade de Tratamento de Gás Natural que é foco do estudo, o ciclo de atividades de gerenciamento de alarmes aplicado na planta, bem como os resultados obtidos com esta forma de gestão. Na sequência, são mostradas as ocorrências de alarmes que são discutidas em termos de funções de probabilidade e de análises de correlação. O Capítulo 4 é destinado ao estudo do caso simulado. Neste capítulo, são apresentados os modelos fenomenológicos utilizados nas simulações, a configuração do sistema de alarmes proposto, os cenários de falhas testados e, finalmente, a discussão dos resultados obtidos em cada cenário de falha. O Capítulo 5 apresenta as conclusões deste trabalho e as sugestões para os trabalhos futuros são expostas. Por fim, são apresentadas as referências bibliográficas utilizadas neste trabalho e um apêndice, com descrições de códigos computacionais usados.

Essa tese foi desenvolvida no LMSCP (Laboratório de Modelagem, Simulação e Controle de Processos) da COPPE (Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia) da UFRJ (Universidade Federal do Rio de Janeiro).

2. REVISÃO BIBLIOGRÁFICA

Este capítulo se inicia na seção 2.1 com a contextualização dos alarmes dentro da área de segurança de processos e detecção e diagnóstico de falhas. Na seção 2.2 são detalhados os problemas em sistemas de alarmes mais abordados da literatura e na seção 2,3 os indicadores de desempenho mais comumente utilizados para monitoramento desses sistemas. As seções 2.4, 2.5 e 2.6 são destinadas ao detalhamento das ferramentas estatísticas que serão utilizadas neste trabalho como ferramentas de auxílio para a simplificação de sistemas de alarmes, sendo elas a análise de correlação, análise de agrupamentos e análise de componentes principais, respectivamente. Na seção 2.7 são feitas as considerações finais deste capítulo.

2.1. O Alarme Inserido no Contexto da Segurança de Processos

Alarme (*alarm*) é qualquer meio auditivo ou visual que indique uma condição anormal associada ao processo ou equipamento (sistemas ou instrumentos) e que exige uma ação em um tempo restrito. Sistema de alarmes (*alarm system*) é o conjunto de *hardware* e *software* que possibilita a anunciação do alarme e permite registrar suas alterações (ISA, 2009; EEMUA, 2013). Alarmes estão inseridos nas diversas áreas do conhecimento e podem ser analisados sob diversas perspectivas. Mas, em uma planta industrial os alarmes são, normalmente, utilizados para monitorar a qualidade da produção e/ou a segurança do processo.

No contexto da segurança de processos os alarmes podem ser melhor compreendidos a partir do conceito de camadas de proteção ilustrado na Figura 1. Numa planta industrial, normalmente, a 1ª camada de proteção compreende o sistema de controle, cuja função primordial é permitir a otimização da produtividade, estruturada em termos de diminuição dos custos de produção e da melhoria da qualidade e segurança dos processos. Os alarmes fazem parte da 2ª camada de proteção, localizados entre o sistema de controle e o sistema de instrumentado de segurança (SIS), também conhecido como *emergency shutdown system* (ESD). A função do SIS é interromper automaticamente o funcionamento do processo, buscando garantir a integridade dos equipamentos, das pessoas e do meio ambiente.

Na 4ª camada estão os dispositivos de proteção ativa, tais como, as válvulas de alívio (*pressure safety valve* – PSV) e os discos de rupturas. Estes dispositivos têm a função de aliviar rápida e automaticamente o inventário presente em um equipamento do processo que, normalmente, são tanques, vasos, torres, bombas, compressores, reatores *etc*, mas também podem ser tubulações. A proteção passiva faz parte da 5ª camada de

proteção. Nela estão os diques e bacias de contenção cujo propósito é isolar o inventário perdido para o ambiente externo. Por fim, na 6ª camada de proteção estão os planos de emergências focados, principalmente, no abandono de área.

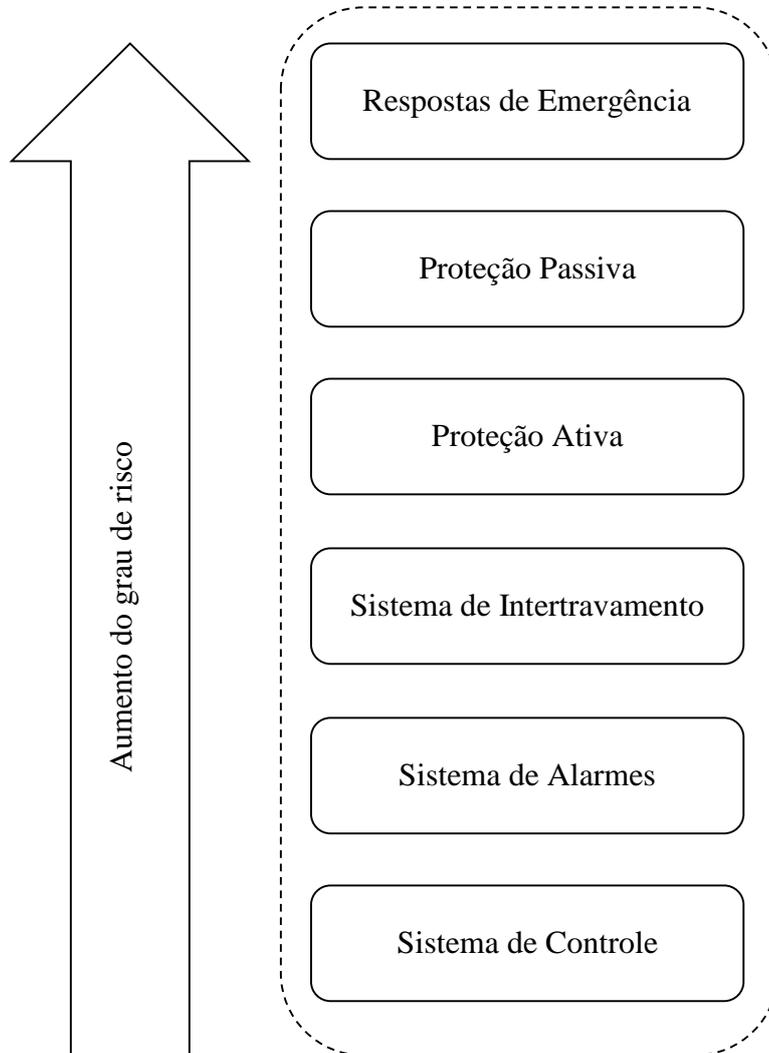


Figura 1. Exemplo de camadas de proteção em planta industrial (Adaptado de CONTEC, 2012).

Como os alarmes são utilizados para indicar a presença de falhas no processo é igualmente importante conceituar este termo. De acordo com Sartori (2012), a falha representa qualquer desvio de uma característica em relação aos seus requisitos, podendo ou não afetar a capacidade de desempenhar uma função requerida.

Segundo Chiang *et al.* (2001) as falhas podem ser classificadas quanto ao local de ocorrência em:

- Mudanças nos parâmetros do processo: ocorrem por uma perturbação externa ao processo. Portanto, a dinâmica não está relacionada ao processo. Por exemplo, uma mudança na concentração de entrada de uma planta de processamento de gás natural ou a mudança no coeficiente de troca térmica de um trocador de calor devido à incrustação, entre outros;
- Mudanças estruturais: ocorrem nos componentes do processo e resultam em mudanças no fluxo de informação entre as variáveis do processo. Por exemplo, agarramento de válvula, vazamento em tubulação *etc*;
- Mudanças nos instrumentos: ocorrem nos sensores e atuadores do processo e podem estar associadas a uma falha fixa, um desvio constante ou uma leitura fora da escala.

Gertler (1988), Isermann (2006) e Palma *et al.* (2002) classificam as falhas quanto ao tipo de sinal em:

- Aditivas: afetam o sinal de resíduo, somando um valor às entradas e/ou às saídas do sistema. Podem ser divididas em panes aditivas de medida e panes aditivas de processo. O primeiro tipo se refere às diferenças entre as medidas das variáveis e os valores reais (relacionado aos sensores) ou entre o valor pretendido e o realizado (relacionado aos atuadores). O segundo tipo são distúrbios (entradas desconhecidas) que agem sobre o sistema;
- Multiplicativas: afetam o sinal de resíduo, sendo um produto dos termos do estado ou do controle com os desvios dos parâmetros. São mudanças (abruptas ou graduais) de parâmetros do processo. Estas falhas descrevem melhor a deterioração de equipamentos, tal como a perda de potência, perda de capacidade de troca térmica, perda de eficiência entre outros.

Segundo Teixeira (2000), Palma *et al.* (2002) e Rivera (2007), as falhas também podem ser classificadas com relação à sua evolução temporal em:

- Abruptas: ocorrem com mudanças rápidas nas variáveis do processo. Surgem quando há um distúrbio atuando diretamente no processo, a partir das vizinhanças, através de uma ou mais variáveis externas;

- Incipientes: ocorrem de modo gradual, evoluindo lentamente com o transcorrer do tempo. Ocasionalmente ocasionam perda de desempenho do sistema e fadiga nos componentes sobrecarregados. Muitas vezes os efeitos destas falhas são encobertos pela ação dos controladores envolvidos, sendo, portanto, difíceis de serem detectadas;
- Intermitente: são aquelas que aparecem e desaparecem no transcorrer do tempo, sem que ocorra qualquer ação de correção.

Para o caso particular dos sensores (dispositivo que responde a um estímulo físico/químico de maneira específica e mensurável) as falhas ainda podem ser classificadas como desvios (*bias*), tendências (*drift*), ruídos ou falha completa do sensor. *Bias* e ruídos são falhas aditivas; *drift* são falhas incipientes; falhas completas do sensor podem ser abruptas ou intermitentes, apresentando comportamento totalmente anômalo como leituras em fundo de escala (*out-of-range failure*) ou valores com variações muito grandes e rápidas (VENKATASUBRAMANIAN *et al.*, 2003a). A Figura 2 resume, através de um diagrama de blocos, as localidades onde as falhas ocorrem com mais frequência num ambiente industrial.

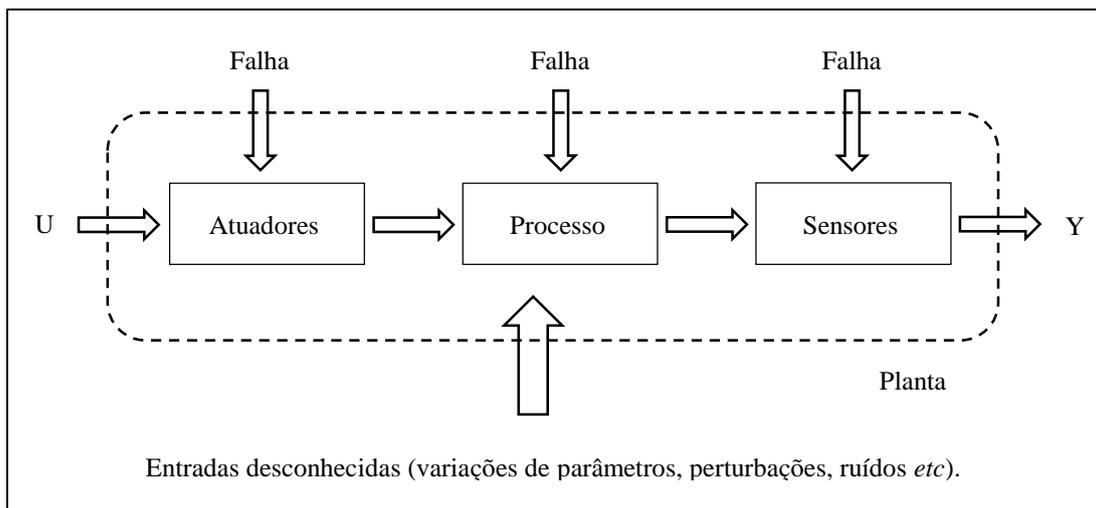


Figura 2. Possíveis localização da falha em uma planta industrial.

A área de detecção, diagnóstico e correção de falhas (*fault detection, diagnosis and correction* – FDD) ganha cada vez mais destaque na área acadêmica (SARTORI, 2012). Em linhas gerais, Frank *et al.* (2000) e Venkatasubramanian *et al.* (2003a) mencionam que um sistema FDDC contempla, pelo menos, três etapas distintas:

- Detecção de falhas (*fault detection*): é a determinação da presença de uma falha no sistema. Esta etapa indica que algo está errado com o sistema e, portanto, existe um comportamento indesejável ou inaceitável;
- Diagnóstico de falhas (*fault diagnosis*): é a determinação das características das falhas detectadas que variam de acordo com o objetivo de cada sistema, sendo a localização, o tipo, a magnitude, a causa, o instante e o comportamento com o tempo as mais corriqueiramente abordadas na literatura;
- Correção de falhas (*fault correction*): é a tomada de ações apropriadas, automática ou não, para restabelecer a capacidade de desempenhar a função requerida. Dentre as ações mais comuns estão a parada, mudanças na operação, reconfiguração, manutenção ou reparo do sistema.

Sistemas de alarmes bem configurados às condições de operação de uma planta industrial devem ser capazes de informar a presença de falhas no processo. Portanto, se num contexto de qualidade é aceitável que os alarmes assumam um comportamento aleatório (ou estocástico), num contexto de segurança de processos esta ideia parece ter pouca aceitabilidade. Em outras palavras, os alarmes utilizados para monitorar a segurança das operações de uma planta industrial devem estar obrigatoriamente associados a eventos determinísticos bem definidos.

2.2. Principais Problemas em Sistemas de Alarmes

Os problemas apresentados a seguir não envolvem questões relacionadas às práticas de gestão de um sistema de alarme, muito embora se saiba que a falta de gestão e de uma filosofia de alarme claramente definida contribui de maneira significativa para os problemas que serão apresentados nesta seção. A falta de gestão determina a inserção de alarmes nas plantas industriais sem, contudo, levar em consideração a capacidade humana de interação com este sistema.

No que se refere à configuração de sistemas de alarmes, algumas características devem ser previstas para facilitar o tratamento dos dados na fase de operação. Kondaveeti *et al.* (2012) destacaram que as informações mais importantes que devem estar presentes em um sistema de alarmes são o tempo exato da ativação do alarme (*time stamp*), o nome do alarme (*tag name*) e a mensagem que o alarme transmite para o operador (*alarm message*). Para ANSI/ISA-18.2 (ISA, 2009) e EEMUA (2013), os alarmes precisam ter níveis de prioridades associados aos sinais e estes devem estar restritos a, no máximo,

quatro níveis: baixo (*Low – LO*), muito baixo (*Low-Low – LOLO*), alto (*High – HI*) e muito alto (*High-High – HIHI*). Esta limitação facilita a gestão dos alarmes, principalmente em situações em que o número de ocorrências é demasiadamente grande. Segundo Rothenberg (2009), a configuração do nível de prioridades dos alarmes em uma planta industrial varia em função das características dos processos envolvidos, conforme pode ser observado na Tabela 1.

Tabela 1. Configuração dos níveis de prioridade dos alarmes (ROTHENBERG, 2009).

Prioridade	EEMUA	Óleo e Gás	Petroquímica	Energia
Alta	5%	35%	35%	35%
Média	15%	15%	15%	15%
Baixa	80%	25%	25%	25%

A priorização dos alarmes também deve ser realizada na fase de operação, dinamicamente e em tempo real. Satuf *et al.* (2014), desenvolveram um sistema especialista para auxiliar os operadores a terem um conhecimento mais abrangente do processo durante perturbações que levem a ocorrência de uma avalanche de alarmes. Larsson e Joseph (2007) utilizaram redes neuronais para priorizar alarmes em momentos de intensa ativação. Figueredo (2016) também utilizaram redes neuronais para detectar e diagnosticar automaticamente cenários de falhas e distúrbio ocorridos em um sistema de tratamento da água produzida em plataformas de petróleo. As redes utilizavam as ativações dos alarmes ao longo do tempo para realizar os diagnósticos.

Soares *et al.* (2013) propuseram o uso integrado de simulação dinâmica em Hysys como programação em *Visual Basic For Applications* (VBA) para analisar o comportamento dos alarmes em plantas petroquímicas. Pariyani *et al.* (2012 a/b) propuseram uma metodologia de análise de risco dinâmico que usa bancos de dados de alarme para melhorar a segurança do processo e a qualidade do produto. A metodologia consiste em rastrear eventos anormais durante um período prolongado de tempo, compactar os dados através do uso de árvores de eventos e calcular a probabilidade da ocorrência de incidentes através de lógica Bayesiana.

A proposta de inserção de um alarme deve sempre estar vinculada a estudos de análises de riscos, envolvendo uma análise criteriosa dos aspectos de segurança de processo, saúde ocupacional e meio ambiente. Algumas técnicas de análise de riscos

foram discutidas em Tixier *et al.* (2002). Normalmente, a ativação do alarme acontece quando uma variável medida (pressão, diferencial de pressão, temperatura, nível, vazão, concentração, vibração, velocidade, dentre outras) ultrapassa o valor do ponto de atuação do alarme previamente estabelecido. Isto indica que a variável monitorada se aproxima de um valor indesejável ou potencialmente inseguro.

Segundo Venkatasubramanian *et al.* (2003a), a geração do sinal de alarme pode ser muito simples (como uma diferença entre uma variável de processo e um limite de alarme pré-fixado) ou complicada (como o uso de ferramentas de aprendizado de máquina para a geração do sinal). Por isso, EEMUA (2013) destacou que os alarmes podem ser classificados em função do tipo de estratégia utilizada para gerar o sinal anunciador. Como:

- Alarmes absolutos (*absolute alarms*): gerados pela comparação entre um sinal analógico e um limite absoluto pré-definido;
- Alarmes calculados (*calculated alarms*): gerados a partir de alguma sequência de cálculos de eficiência;
- Alarmes desvio (*deviation alarms*): gerados se a diferença entre dois sinais analógicos excede um determinado valor pré-estabelecido;
- Alarmes discrepâncias (*discrepancy alarms*): gerados por meio da comparação de um estado esperado contra o estado real;
- Alarmes de taxa de variação (*rate of change alarms*): gerados pela velocidade de mudança de um sinal analógico com uma configuração pré-definida;
- Alarmes dirigidos (*recipe driven alarms*): gerados em função do estado operacional da unidade;
- Alarmes estatísticos (*statistical alarms*): gerados por meio de algum cálculo estatístico capaz de filtrar mudanças significativas do processo.

Conforme exposto por Arzén (1996), Ghariani *et al.* (2002) e MacDonald (2004), grande parte do problema do elevado número de ativações de alarmes nas plantas industriais está associado ao péssimo ajuste do *setpoint*. Isto porque, na maioria das vezes, estes valores são configurados sem levar em consideração os diferentes estados operacionais da planta como, por exemplo, partida, parada, mudanças de carga, mudanças de produtos, períodos de manutenção *etc.* Na literatura, poucos trabalhos buscaram avaliar a questão dos *setpoints* de alarmes adaptativos. Em parte, talvez isto possa ser

explicado pela dificuldade prática de introduzir este tipo de estratégia nas plantas industriais. O mais comum é manter os *setpoint* fixos, levando-se em consideração apenas a condição de operação normal do processo.

Habibi e Hollifield (2006) propuseram o uso de algoritmos capazes de detectar mudanças entre os estados operacionais do processo e, em função disso, redefinir os *setpoint* de alarmes. O método desenvolvido pode ser aplicado de forma automática ou de forma manual, por intermédio do comando dos operadores. Os resultados obtidos evidenciaram a melhora no desempenho e na confiabilidade do sistema de alarme. Naghoosi *et al.* (2011) apresentaram um estudo sobre a relação entre os limites ótimos de atuação do alarme e a configuração de banda morta. O trabalho propôs a consideração do histórico da variável de processo para estimar o *setpoint* ideal do alarme e a configuração de banda morta.

Conforme apontado por EEMUA (2013), uma condição que parece ser comum a todos os sistemas de alarmes, e que provoca uma elevada taxa de insatisfação com estes sistemas, é a presença de alarmes que são anunciados excessivamente, sem necessidade, ou que não retornam para a condição normal, mesmo após cessar a ação do operador. Estes alarmes são conhecidos por *nuisance alarm* e podem ser traduzidos como alarmes incômodos ou alarmes ruidosos. Alarmes que se repetem excessivamente em curtos intervalos de tempo sobrecarregam o operador com uma série de informações irrelevantes e contribuem para o descrédito gradativo e total dos sistemas de alarmes. De acordo com ISA (2009), a presença de alarmes ruidosos leva os operadores, dependendo da concepção do sistema de alarme, a silenciar a buzina de alarme e/ou a aceitar o alarme cada vez que ele ocorre. Além disso, em alguns modelos, alarmes ruidosos podem encher a lista de alarmes com a mesma mensagem de alarme e, desta forma, ocultar outras mensagens importantes.

Para Dunn e Sands (2005) e Larsson (2000), os alarmes ruidosos acabam reduzindo o tempo de resposta do operador aos alarmes reais. Conforme discutido em IEC (2014), uma forma de *nuisance alarm* são os alarmes de repetição, ou alarmes de vibração, ou ainda *chattering alarm*. Um alarme pode ser repetido por uma série de razões, incluindo instrumentação com defeito ou *setpoint* mal configurado. De acordo com Bransby e Jenkinson (1998), cerca de 50% das ocorrências de alarmes em uma planta industrial estão associadas à presença de alarmes de vibração. Ghariani, Toguyéni e Craye (2002) destacam que muitas vezes os alarmes de vibração podem ser interpretados como falso alarmes. É o caso, por exemplo, de um equipamento em manutenção. Neste caso,

sempre que controlador tentar executar uma rotina de controle, ficará sem resposta e acionará uma ativação de alarme no processo.

Uma das dificuldades de lidar com o problema de alarmes de repetição é definir um conjunto de características que permite sua identificação. Em outras palavras, definir o momento que se deve atuar no sistema. O alargamento dos *thresholds* pode constituir uma solução rápida para reduzir as ocorrências de alarmes de vibração. Porém, este tipo de ação deve sempre ser precedida de uma análise criteriosa dos riscos envolvidos. Por exemplo, a Figura 1 ilustra uma situação em que há um grande desvio da variável monitorada. Contudo, em função de *threshold* muito expansivo, não ocorre ativação do alarme, pois a variável monitorada não toca os limites de atuação do alarme. Talvez esta seja uma situação até mais problemática do que a presença de alarmes de vibração. A Figura 2 ilustra um exemplo com *thresholds* muito conservadores em que a variável monitorada cruza os limites de atuação do alarme com maior frequência (SOARES *et al.*, 2013).

Outro problema comum são os alarmes com duração muito elevada. Estes alarmes permanecem ativos por um longo período de tempo, geralmente por não requererem qualquer ação operacional ou por não terem retornado ao estado normal após as ações corretivas dos operadores (DUNN e SANDS 2005). Estes alarmes problemáticos acabam inundando as telas de alarmes, podendo mascarar outros alarmes importantes do operador. Normalmente, estes alarmes permanecem no estado ativado durante dias, semanas ou meses (ISA, 2009). Estes alarmes são chamados de alarmes silenciosos, ou alarmes obsoletos, *stale alarm*. Para IEC (2014), os alarmes silenciosos representam uma forma de *nuisance alarm* e são aqueles sinais que permanecem ativos continuamente por longos períodos de tempo, geralmente superiores a 24 horas.

Alarmes com duração muito elevada podem configurar uma falta de estratégia de inibição dos alarmes de equipamentos em manutenção ou mesmo uma falha na concepção do ponto de ativação. Como exemplo, considere a existência de um vaso separador que tem como ponto de operação de nível em regime permanente o valor de 1 metro e alarme de nível alto com ponto de ativação em 0,8 metro. Fatalmente este alarme perdurará por horas ou até dias na tela de operação. Apesar de óbvio, este erro é bastante comum em ambientes industriais (LEITÃO, 2008). As Figuras 3 a 5 mostram dados reais obtidos neste trabalho para situações em que o *setpoint* do alarme é muito expansivo, muito conservador e bem ajustado às condições de operação do processo, respectivamente.

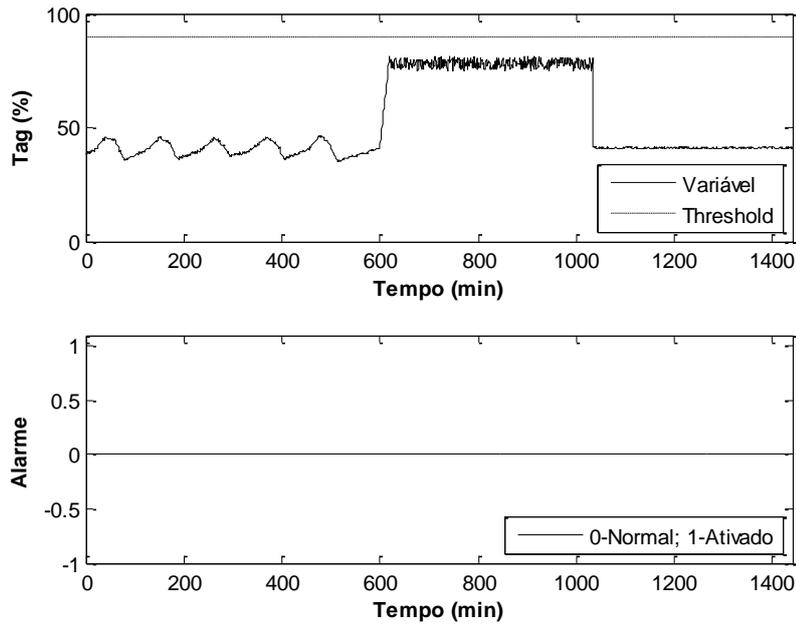


Figura 3. Exemplo de *setpoint* de alarme muito expansivo.

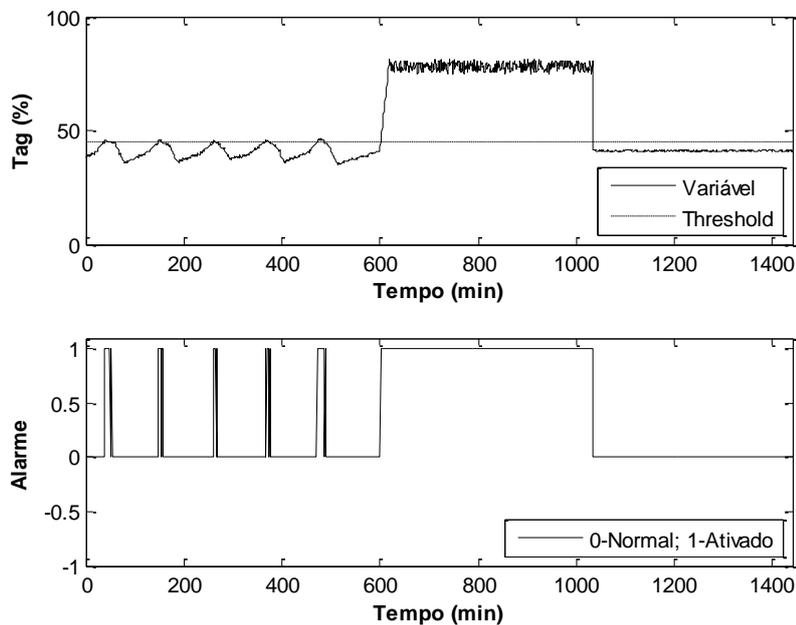


Figura 4. Exemplo de *setpoint* de alarme muito conservador.

Segundo Dunn e Sands (2005), um dos mais perigosos problemas com os sistemas de alarmes, e também mais complexo de se resolver, são as avalanches de alarmes. Para Fritzen *et al.* (2010), avalanches de alarmes são o foco de maior atenção dos trabalhos disponíveis da literatura. De acordo com ISA (2009) e EEMUA (2013), as avalanches de alarmes, ou *alarm flood*, representam uma condição durante a qual a taxa de alarmes é

maior do que aquela que pode ser efetivamente gerenciada. As avalanches sobrecarregam os operadores, tornando bastante difícil a tarefa de determinar a causa da anormalidade. Considera-se como avalanche de alarmes a ocorrência de mais de 10 alarmes no intervalo de 10 minutos.

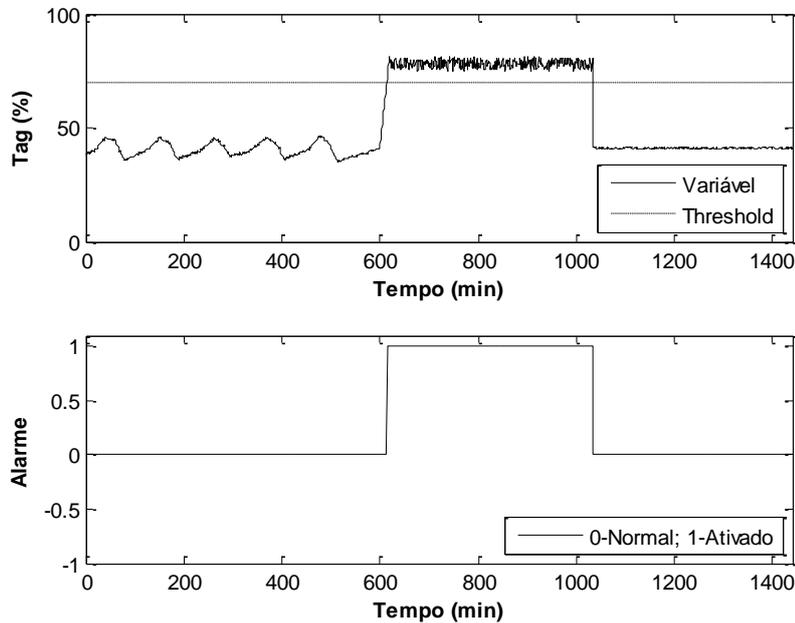


Figura 5. Exemplo de *setpoint* de alarme bem configurado.

Para Burnell e Dicken (1997), sob condições normais de operação um operador é perfeitamente capaz de lidar com uma taxa de ativação de 2 a 3 ocorrências de alarmes por minuto. Porém, em situações de distúrbios a taxa de ativação pode superar os 10 alarmes por minuto e exigir muito mais do operador. Para Mattiasson (1999), avalanches de alarmes são causadas na maioria das vezes pela propagação de uma falha ao longo do processo. Larsson *et al.* (2007) e AHMED *et al.* (2011) destacam que avalanches de alarmes podem ocorrer tanto em momentos de transição da planta (parada, partida, *shutdown, trip etc*), como em situações de operação normal.

2.3. Indicadores de Desempenho

Conforme apresentado em EEMUA (2013), existe uma série de maneiras para aferir o desempenho de um sistema de alarme: questionários aplicados ao operador, pesquisas sobre a utilidade do alarme, registro de incidentes, avaliação do número de alarmes em um sistema, medição da taxa média de ocorrências de alarme, identificação

dos alarmes mais frequentes, medição do número de ativações de alarmes após uma grande mudança operacional na planta, medição do tempo de resposta do operador, medição do número de alarmes permanentes, análise da distribuição das prioridades dos alarmes configurados e que ocorrem no processo, análise de correlação, entre outras. De maneira geral, a Tabela 2 apresenta os indicadores de desempenho mais utilizados nas plantas industriais. Entende-se que, ao manter a taxa de ocorrências de alarmes abaixo destes valores limites, o operador seja perfeitamente capaz de detectar e diagnosticar as causas associadas à ativação do alarme, navegar no sistema de controle e, caso seja necessário, executar uma ação de correção.

Tabela 2. Métricas de desempenho para monitoramento de sistemas de alarmes.

Métrica por operador	Meta
Alarmes anunciados por dia (média)	< 144
Alarmes anunciados por hora (média)	< 6
Alarmes anunciados por período de 10 minutos	< 1
Percentual de horas com incidência superior a 30 alarmes	< 1%
Períodos de 10 minutos com incidência superior a 10 alarmes	< 1%
Número máximo de alarmes em um período de 10 minutos	< 10
Distribuição de prioridades dos alarmes anunciados	
Baixa	~ 80%
Média	~ 15%
Alta	~ 5
Crítica	< 1%

O objetivo principal dos indicadores de desempenho é avaliar o desempenho do sistema de alarme e identificar uma variedade de problemas, incluindo a presença de alarmes incômodos que precisam ser modificados de alguma forma, bem como as dificuldades mais genéricas associada a configurações incorretas, mensagens de alarme inadequadas, alarmes de vibração, entre outras.

Segundo EEMUA (2013), as técnicas de monitoramento de alarmes podem ser classificadas como de alto e médio benefício. As técnicas de alto benefício envolvem a avaliação continuada do comportamento do alarme para confirmar sua utilidade, para evitar alarmes incômodos, para eliminar alarmes que não requerem resposta definida do operador, para garantir que os alarmes críticos sejam visualizados e tratados

primeiramente, para rever as mensagens de alarmes que os operadores não entendem ou não sabem como responder, para introduzir mecanismos de tempo de prateleira, dentre outras. As técnicas de médio benefício envolvem a supressão de alarmes em situações que envolvam parada de planta, substituição de alarmes absolutos por alarmes de desvio, aplicação de filtros e temporizadores, introdução de lógicas capazes de combinar e simplificar conjuntos de alarmes redundantes, dentre outras.

Na área industrial, alguns métodos simples podem ser aplicados para reduzir o problema de *chattering alarm*, como o uso de banda morta (*deadband*), tempo de atraso (*delay time*) e filtros (*filtering*). A banda morta é a faixa dentro da qual o alarme não tem seu estado alterado, independentemente da variação do sinal lido. Esta configuração normalmente é uma porcentagem do *range* do instrumento de medição. O filtro representa o tempo em que os algoritmos geradores dos sinais de alarmes devem ser acionados, ou seja, a frequência com que o sinal de alarme deve ser amostrado pelo sistema de alarmes.

O tempo de atraso estabelece uma contagem de tempo para a geração dos alarmes subsequentes. Em outras palavras, após a primeira ocorrência do alarme as demais só serão anunciadas se a variável do processo permanecer na região do *setpoint* do alarme por período de tempo igual ou superior ao tempo de atraso definido. Estas estratégias são apresentadas em ISA (2009) e EEMUA (2013).

As Tabelas 3 a 5 mostram valores típicos de *deadband*, *delay time* e *filtering*, respectivamente. Estes parâmetros podem ser utilizados como ponto de partida, quando não se têm muitas informações a respeito das dinâmicas do processo. O uso de *filtering*, *delay times* e *deadband* oferecem uma forma eficiente e de fácil aplicação para reduzir a quantidade de alarmes repetitivos, mas não atua na causa que desencadeou a repetição do alarme. Além disso, sempre introduz tempo de atraso na geração do sinal de alarme.

Tabela 3. Valores sugeridos para configuração de banda morta (EEMUA, 2013).

Variável de Processo	<i>Deadband</i> (% do range)
Vazão	5
Nível	5
Pressão	2
Temperatura	1

Tabela 4. Valores sugeridos para configuração de tempo de atraso (EEMUA, 2013).

Variável de Processo	<i>Delay Times</i> (segundos)
Vazão	15
Nível	60
Pressão	15
Temperatura	60
Outros	5

Tabela 5. Valores sugeridos para configuração de filtro temporizador (EEMUA, 2013).

Variável de Processo	<i>Filtering</i> (segundos)
Vazão	2
Nível	2
Pressão	1
Temperatura	0

A Figura 6 mostra um exemplo de comportamento dinâmico do sinal do alarme numa planta industrial. Em (A) a variável de processo encontra-se em estado normal. Portanto, não há nenhuma ativação de alarme. Em (B) a variável atinge o ponto de atuação do alarme. Porém, a anúncio do alarme não ocorre de forma instantânea em função do tempo de atraso característico do processo e do próprio sistema de alarme. Conseqüentemente, enquanto não houver a anúncio do alarme, também não haverá reconhecimento deste sinal pelo operador. Em (C) há ação de resposta que pode ser eficaz, levando a variável de processo ao estado normal representado por (D) ou não. Neste último caso, haveria conseqüências indesejadas para o processo, pois o limite de conseqüência seria ultrapassado. Observa-se ainda que dentro da região (C) diversas dinâmicas se fazem presentes. Por exemplo, o operador pode não responder a uma ativação de alarme, levando o processo a uma região de operação insegura. O operador também pode responder a uma ativação de alarme, mas existe um tempo morto mínimo entre a percepção do sinal e a ação realizada. Somente após este tempo ocorre algum tipo de intervenção no processo. O processo, por sua vez, também apresenta um tempo morto e não reage instantaneamente com a intervenção do operador. Se a ação foi eficaz, então a variável medida retorna a sua condição normal. Porém, a ativação do alarme depende da presença ou não de banda morta. Se existir banda morta, o alarme só retorna a sua condição de normalidade após a variável de processo ultrapassar o valor configurado.

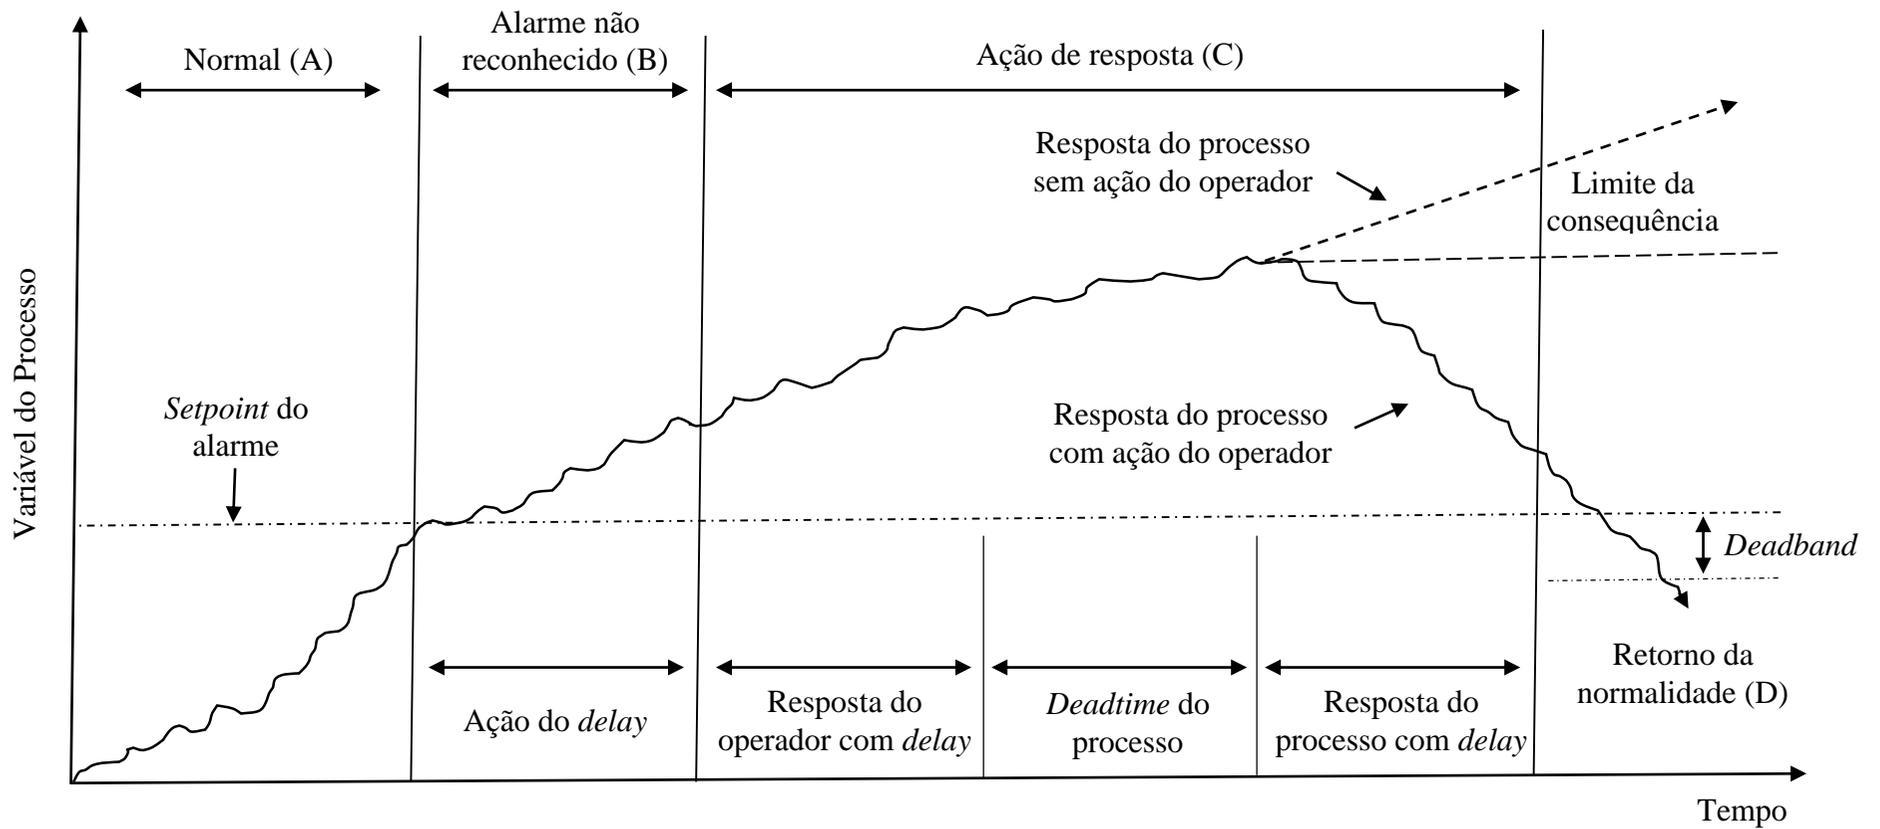


Figura 6. Exemplo de comportamento dinâmico do sinal de alarme em uma planta industrial (Adaptado de ISA, 2009)

Na área acadêmica, diversos trabalhos têm sido desenvolvidos para abordar os diferentes problemas que podem ocorrer em sistemas de alarmes. Burnell e Dicken (1997) apresentaram uma breve introdução sobre o problema da repetição de alarmes e apresentaram duas abordagens diferentes para reduzir o *chattering alarm*. A primeira abordagem deve ser utilizada a nível de sistema supervisor e oferece ao operador um mecanismo manual de tempo de prateleira. A segunda abordagem deve ser incorporada no próprio sistema de controle de processo e utiliza o tempo de atuação do alarme para iniciar um mecanismo de tempo de prateleira automático. Larsson (2000) destacou que, para melhorar o sistema de alarme de uma planta industrial, é preciso detectar limites de alarme indevidamente sintonizados e reajustar estes limites para os valores corretos, um processo que o autor chama de saneamento do alarme. Neste trabalho foi proposto um método para detectar alarmes suspeitos e sugerir novos limites de alarme.

Naghoosi *et al.* (2012) desenvolveram um método para estimar o índice de ativação do alarme com base nas propriedades estatísticas da variável de processo e nos parâmetros de configuração. A estimativa pode ser usada para o desenvolvimento de métodos analíticos para a concepção ótima desse parâmetro. Xu *et al.* (2012) estudaram o desempenho de um sistema de alarmes avaliando a taxa de falsos alarmes, a taxa de alarmes perdidos e o tempo de atraso da ativação do alarme. Exemplos numéricos e um estudo de caso industrial foram utilizados para verificar o desempenho do método desenvolvido. Adnan *et al.* (2012) propuseram o uso da técnica de Markov para detectar tempo de atrasos com o uso de banda morta, filtro e tempo morto. A técnica permitiu reduzir atrasos na detecção de falsos alarmes e na taxa de alarmes perdido, proporcionando maior confiança operacional ao sistema.

Para Antunes (2011), avalanches de alarmes podem ser resolvidas por meio de uma triagem eficaz dos alarmes, capaz de desconsiderar todas as informações que não colaboram para a compreensão dos eventos. Kondaveeti *et al.* (2012) discutiram o conceito de comprimento de percurso (*run lengths*), introduzindo no contexto de gerenciamento de alarme para propor um índice capaz de quantificar *chattering alarms* com base em dados históricos de alarme. O comprimento de percurso nada mais é do que o tempo, em segundos, entre duas ativações de alarmes consecutivos dentro de uma janela de amostragem. Wang e Chen (2013) propuseram um método *on-line* para detectar e reduzir alarmes intermitentes. A técnica inicialmente estabelece um limite aceitável para a intermitência do alarme com auxílio da transformada discreta do cosseno. Posteriormente, dois mecanismos foram propostos para ajustar o *setpoint* do alarme e o

para ajustar o temporizador. A eficácia do método foi comprovada em um estudo de caso industrial.

2.4. Análise de Correlação

O resultado de qualquer medição pode ser considerado como uma aproximação, ou estimativa, do valor do mensurando. Assim, a medição só é completa quando acompanhada pela declaração da incerteza (GUM, 2008). Em uma planta industrial, isto não poderia ser diferente, de maneira que todas as variáveis medidas e utilizadas para monitoramento são compostas pelos sinais de processo (informação), por sinais do sistema de medição (ruído) e por sinais de falhas, quando houver (FEITAL, 2011). A Figura 7 apresenta as componentes que estão associadas a uma variável de processo. Parece intuitivo pensar que, se as variáveis de processo apresentam certa variabilidade, então os alarmes gerados a partir de tais variáveis também devem apresentar algum grau de incerteza. Por isto, tanto as variáveis de processo quanto os alarmes só podem ser definidos dentro de um certo limite estatístico de confiança.

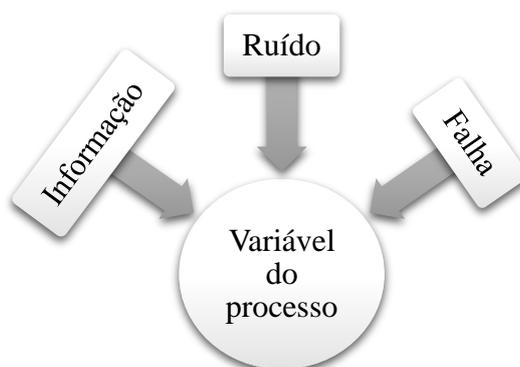


Figura 7. Componentes de uma variável de processo (FEITAL, 2011).

Conforme destacado por Pinto e Schwaab (2007), o estabelecimento do nível de confiança é equivalente à definição da fração de vezes que um erro pode ser tolerado. Por exemplo, ao se dizer que uma variável aleatória está 95% das vezes dentro de um intervalo de confiança, diz-se simultaneamente que ela pode não estar naquele intervalo 5% das vezes por razões meramente aleatórias. Cada processo e cada analista define o intervalo de confiança adequado para a análise a ser executada. Por exemplo, se uma eventual decisão equivocada não envolve riscos nem custos muito grandes, pode-se trabalhar com níveis de confiança mais baixos e aumentar a velocidade do processo para a detecção de

falhas ou de mudanças do processo. Por outro lado, se uma eventual decisão equivocada pode comprometer seriamente a segurança ou a economia do processo, deve-se trabalhar com níveis de confiança mais altos, sabendo-se que essa estratégia certamente provocará atrasos no processo de tomada de decisão.

O nível de confiança está diretamente associado ao conceito de probabilidade, tendência central e espalhamento. A probabilidade (p_i) pode ser expressa como a fração, ou frequência (f_i) de vezes, que se espera que o resultado experimental ocorra, quando o experimento é realizado um número muito grande de vezes (N_T), tendendo ao infinito (PINTO e SCHWAAB, 2007). A probabilidade é necessariamente um número contido no intervalo $[0, 1]$ e a soma das probabilidades sempre será igual a 1. Matematicamente, a probabilidade pode ser escrita na forma da Equação (1):

$$p_i = \lim_{N \rightarrow \infty} \left(\frac{f_i}{N} \right) \quad (1)$$

Uma vez conhecidos os possíveis resultados de um problema e as probabilidades associadas a cada um destes resultados, conhece-se praticamente tudo sobre o destino do experimento. Este acúmulo de conhecimento pode ser representado numa forma gráfica bastante conveniente, chamada de histograma. Como não é possível repetir um experimento infinitas vezes, por limitações reais de tempo e custo, o conceito de probabilidade usado para descrever problemas reais não pode ser obtido unicamente por métodos experimentais. Na prática, o que se tem são modelos idealizados. Normalmente, modelos são construídos com auxílio dos dados obtidos nas condições normais de operação. Ou seja, admite-se que a parcela de falhas seja nula, restando apenas a informação e o ruído de medição (PINTO e SCHWAAB, 2007).

As variáveis utilizadas para a construção de um modelo de probabilidade podem ser contínuas (características mensuráveis que assumem valores em uma escala contínua, para as quais valores fracionais fazem sentido) ou discretas (características mensuráveis que podem assumir apenas um número finito de valores e, assim, somente fazem sentido valores inteiros). Exemplos de funções de probabilidade contínuas são as distribuições Beta, Exponencial, Gamma, Log-normal, Normal, Rayleigh, Uniforme, Valores Extremos e Weibull. Exemplos de funções de probabilidade discretas são as distribuições de Bernoulli, Binomial, Poisson, Geométrica, Binomial Negativa, Hipergeométrica, Multinomial, dentre outras (MONTGOMERY, 2009).

Uma vez que as observações individuais (informação) diferem em valor por causa dos erros grosseiros (falhas) e dos aleatórios (ruídos), é conveniente que todos os possíveis resultados de um experimento possam ser representados por um único valor em torno do qual as probabilidades se distribuem. Para Pinto e Schwaab (2007), a estimativa mais utilizada para este fim é a média aritmética (μ) que, apenas para o caso particular em que a probabilidade associada aos eventos é constante durante todo o período de amostragem, pode ser escrita na forma da Equação (2):

$$\mu = \frac{1}{N} \sum_{i=1}^N X_i \quad (2)$$

Caracterizada a tendência central dos resultados de um experimento, pode-se quantificar o espalhamento do conjunto de dados com relação a esta tendência. Pinto e Schwaab (2007) destacam que a forma mais usual para isto é a variância (σ^2_{xx}) que, apenas no caso particular onde a probabilidade associada ao evento é constante durante todo o período de amostragem, pode ser escrita na forma da Equação (3):

$$\sigma^2_{xx} = \frac{1}{N-1} \sum_{i=1}^N (X_i - \mu)^2 \quad (3)$$

Segundo Pinto e Schwaab (2007), como a variância tem dimensão do quadrado da variável, é útil definir uma outra grandeza dimensional para representar o espalhamento dos dados. Para isto, utiliza-se o desvio-padrão (σ_x) que, no caso particular em que a probabilidade associada ao evento é constante durante todo o período de amostragem, pode ser representado conforme a Equação (4):

$$\sigma_x = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (X_i - \mu)^2} \quad (4)$$

Durante as análises de dados que envolvam comparações entre grandezas físicas, as diferentes unidades de engenharia envolvidas podem gerar falsas interpretações. De acordo com Vicini (2005), a estratégia mais comum para abordar este problema é tornar

todas as medidas adimensionais por intermédio de um procedimento de normalização ou padronização dos dados. As variáveis normalizadas adimensionais (Z_i) podem ser obtidas fazendo-se a diferença entre as medidas individuais (X_i) e a média (μ) e dividindo o resultado obtido pelo desvio-padrão, conforme mostra a Equação (5). Este mecanismo proporciona uma nova distribuição dos dados com média igual a 0 e desvio-padrão igual a 1.

$$Z_i = \frac{X_i - \mu}{\sigma} \quad (5)$$

Sob o ponto de vista experimental, como não é possível controlar todo o universo de influências que afetam um certo experimento, o ideal é que as incertezas (ou variabilidade, ou ainda erro experimental) sejam tão pequenas quanto possível, indicando que se exerce um controle bastante efetivo sobre as variáveis mais relevantes para a consecução dos dados experimentais obtidos. Conforme destacado por Pinto e Schwaab (2007) pode ser perda de tempo aplicar técnicas estatística rebuscadas para a análise dos dados se os dados experimentais apresentam muitas incertezas e, portanto, não são apropriados para esta finalidade.

Existem diversas maneiras para avaliar se um conjunto de dados experimentais está ou não adequado para a realização de análises estatísticas. O mais comum é calcular o coeficiente de variação (C_v), indicado pela Equação (6), que representa a razão do desvio-padrão pela média aritmética (MONTGOMERY, 2009).

$$C_v = \frac{\sigma}{\mu} \times 100 \quad (6)$$

Conforme indicado em Correia (2003), o coeficiente de variação trata-se de uma medida relativa de dispersão útil para a comparação em termos relativos do grau de concentração. Em geral, $C_v \leq 15\%$ indica baixa dispersão (ótimos dados experimentais), $15\% < C_v \leq 30\%$ reflete média dispersão (bons dados experimentais), $C_v > 30\%$ representa alta dispersão (dados experimentais ruins). Via de regra, os processos apresentam uma dispersão intrínseca e sempre é possível reduzir a dispersão dos dados aumentando o número de experimentos realizados.

As observações que apresentam grande afastamento do valor médio do conjunto de dados são chamadas de observações anormais, contaminantes, estranhas, extremas, aberrantes ou *outliers*. Estas observações contribuem de maneira significativa para o aumento da dispersão dos dados. Por isso, essas observações são frequentemente removidas do conjunto de dados.

Segundo Montgomery (2009), a preocupação com *outliers* é antiga e data das primeiras tentativas de analisar conjuntos de dados. Inicialmente, pensava-se que a melhor forma de lidar com este tipo de observações era a eliminação da análise. Porém, antes de decidir o que deve ser feito com os *outliers* é conveniente ter conhecimento das causas que levam ao aparecimento desses sinais.

As principais causas que levam ao aparecimento de observações anormais são a presença de erros de medição, erros de execução e variabilidade inerente dos elementos da população. Na prática, quando se tem a oportunidade de realizar novamente o experimento, deve-se verificar se após a repetição do mesmo os *outliers* podem ser novamente identificados. Se sim, então é provável que os pontos façam parte do processo e não devam ser eliminados. Estas observações devem ser tratadas cuidadosamente, pois podem conter informação relevante sobre características subjacentes aos dados e podem ser decisivas para o conhecimento da população à qual pertence a amostra em estudo. Se não, então parece haver motivos para desprezar estas observações do conjunto de dados.

O conceito de variáveis padronizadas, discutido anteriormente, representa uma importante ferramenta para a identificação de *outliers*. Conforme apresentado por Pinto e Schwaab (2007), o desvio-padrão, quando somado à média aritmética, delimita uma região em que os resultados mais prováveis podem ser encontrados dentro de um certo limite de confiança.

A Figura 8 ilustra uma curva normal, ou Gaussiana, de distribuição de probabilidades delimitada por quatro regiões distintas ($\pm 1\sigma$, $\pm 2\sigma$, $\pm 3\sigma$ e $\pm 4\sigma$), associadas aos níveis de confiança de 68,26%, 95,44%, 99,73% e 99,994%, respectivamente. Assim, para um intervalo de confiança de 95,44% é muito pouco provável que um valor esteja fora da região $\pm 2\sigma$. Ou seja, os valores de Z_i que estiverem fora desta região, a princípio, podem ser considerados como *outliers*, por serem pouco frequentes e pouco esperados (MONTGOMERY, 2009).

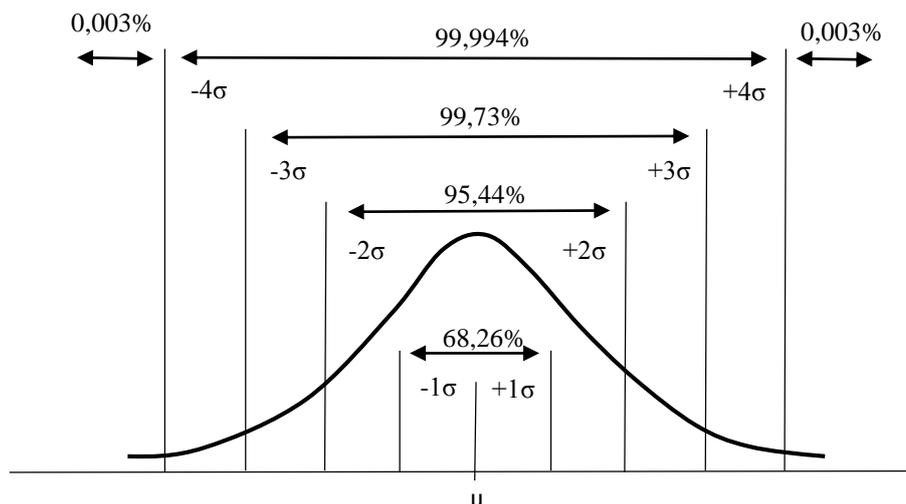


Figura 8. Limites de confiança com curva normal (Adaptado de Montgomery, 2009).

A curva normal de probabilidades é muito utilizada como modelo em um infindável número de aplicações que envolvem variáveis aleatórias contínuas. Parece razoável admitir que, se o instrumento de medição está bem calibrado e funcionando adequadamente (o que nem sempre é uma verdade), os erros de medição podem ser positivos ou negativos, distribuindo-se aleatoriamente em torno da média de forma simétrica. Além disso, quanto maiores são os erros em valor absoluto, menos provável é a sua ocorrência no conjunto de dados. Ambas as condições são naturalmente satisfeitas pela curva normal. Conforme apresentado por Pinto e Schwaab (2007), a distribuição normal de uma variável contínua $D(t)$ é uma função bi-paramétrica que depende da média aritmética (μ_t) e do desvio-padrão (σ), representada pela Equação (7).

$$D(t) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{t - \mu_t}{\sigma}\right)^2\right], \quad -\infty < t < \infty \quad (7)$$

Existe um teorema na estatística, conhecido como Teorema do Limite Central, que diz que os resultados experimentais obtidos da soma de muitos eventos aleatórios apresentam distribuição aproximadamente normal (MONTGOMERY, 2009). Talvez seja essa a razão principal que faz com que a distribuição normal encontre uso generalizado como modelo probabilístico da distribuição de erros de medida. Porém, isto não significa dizer que os erros de medição seguem necessariamente o modelo normal. Nas plantas industriais, desvios da normalidade ocorrem frequentemente com os dados de processo. Por isto, é imprescindível que os dados sejam caracterizados quanto ao tipo de

distribuição que melhor os representa. Pelo menos duas fortes suposições estão associadas à curva Gaussiana. A primeira diz respeito aos conceitos de média, variância e desvio-padrão, que foram definidos considerando que a probabilidade associada ao evento é constante durante todo o período de amostragem. A segunda consiste no fato de que a função de distribuição Gaussiana foi definida para tratar problemas com variável contínua.

De acordo com Chen (2010), Kondaveeti *et al.* (2012), Wang *et al.* (2015) e outros, alarmes são dados binários que podem ser representados pela Equação (8). A forma mais comum para detectar o estado do alarme é comparar o valor da variável contínua analisada, $x_a(t)$, com o valor do *setpoint* de alarme, x_{set} , de alta (ou baixa), previamente definido. Se a variável for maior (ou menor) ou igual ao valor de *setpoint* configurado, produz-se o estado de alarme ativado (1). Caso contrário, produz-se o estado de alarme não ativado (0). Portanto, os estados de alarme ao longo do tempo podem ser representados por uma sequência binária do tipo 0 – 1.

$$x_a(t) = \begin{cases} 1, & \text{se } x_a(t) \geq (\leq) x_{set} \\ 0, & \text{se } x_a(t) < (>) x_{set} \end{cases} \quad (8)$$

A grande maioria dos trabalhos com dados de alarmes utiliza a distribuição binomial para representar estes sinais. Conforme discutido por Pinto e Schwaab (2007), a distribuição binomial é aplicada a eventos aleatórios em que apenas dois resultados são possíveis (sucesso ou insucesso, cara ou coroa, acima ou abaixo, certo ou errado, sim ou não, conforme ou não conforme, ativado ou não ativado). Para a construção da curva, é necessário que as probabilidades de que os resultados ocorram e, conseqüentemente não ocorra, sejam conhecidas e iguais a p e a $q = 1 - p$, respectivamente. Neste cenário, a distribuição binomial procura descrever o seguinte problema: após m repetições do experimento, qual é a probabilidade de obter n sucessos? Matematicamente, a distribuição binomial pode ser escrita conforme a Equação (9) apresentada a seguir:

$$\text{Bin}(n; m; p) = \frac{m!}{n! (m - n)!} p^n q^{m-n} \quad (9)$$

Dentro do contexto das ativações de alarme, o problema poderia ser exposto da seguinte forma: ao se observar m vezes um ponto de alarme, qual a probabilidade deste ponto de alarme estar n vezes alarmado? Montgomery (2009) destaca que a distribuição binomial deve ser aplicada se: i) o experimento for repetido nas mesmas condições; ii) o experimento for repetido um número finito de vezes; iii) as provas repetidas forem independentes (isto é, o resultado de uma medida não afeta os resultados das medidas sucessivas); iv) cada medida resultar em um dos dois possíveis resultados e; v) no decorrer do experimento, as probabilidades serem constantes.

Em um processo decisório, na grande maioria das vezes não é possível estabelecer um plano de ação eficaz com base apenas no comportamento de uma única variável. Variáveis podem estar correlacionadas, de maneira que a média e o desvio-padrão podem não ser os estimadores mais apropriados da estatística desejada. Conforme discutido por Pinto e Schwaab (2007), para caracterizar o grau de independência linear entre resultados obtidos a partir de diferentes experimentos, utiliza-se a covariância (σ^2_{XY}), que, no caso particular em que as probabilidades associadas aos eventos X e Y são constantes durante todo o período de amostragem, pode ser representada pela Equação (10). Se a covariância entre duas variáveis X e Y for um número positivo, então as flutuações do resultado do experimento X acima da média são também normalmente acompanhadas de flutuações do resultado do experimento Y acima da média, e vice-versa. Se a covariância entre duas variáveis X e Y for um número negativo, então as flutuações do resultado do experimento X acima da média são também normalmente acompanhadas de flutuações do resultado do experimento Y abaixo da média, e vice-versa. Eventos independentes resultam em covariância igual a zero.

$$\sigma^2_{XY} = \frac{1}{N_T} \sum_{i=1}^N (X_i - \mu_X)(Y_i - \mu_Y) \quad (10)$$

Como a covariância tem dimensão equivalente ao produto das dimensões das variáveis X e Y e como a magnitude dessas variáveis pode mudar de problema para problema, é conveniente definir uma forma adimensional para o grau de dependência funcional linear entre as variáveis X e Y . A forma adimensional mais usual para o grau de dependência funcional linear entre duas variáveis é o coeficiente de correlação (ρ_{XY}), ou coeficiente de correlação de Pearson (r_{Pearson}), que, no caso particular em que as

probabilidades associadas aos eventos X e Y são constantes durante todo o período de amostragem, pode ser representada conforme a Equação (11). Quanto mais próximo de 1 for o coeficiente de correlação, mais perfeito é o grau de correlação linear direto entre as variáveis. Quanto mais próximo de -1 for o coeficiente de correlação, mais perfeito é o grau de correlação linear inverso entre as variáveis. Quanto mais próximo de 0 for o valor absoluto do coeficiente de correlação, maior é o grau de flutuação independente das variáveis. Variáveis independentes podem indicar independência verdadeira entre os experimentos, existência de erros pronunciados de medição, influência de outras variáveis sobre o experimento ou maior grau de não linearidade da dependência funcional entre as variáveis (PINTO e SCHWAAB, 2007). Normalmente, em uma análise de correlação, os resultados são apresentados na forma de tabelas, em que os coeficientes de correlação entre todas as variáveis são expostos na forma de linhas e colunas.

$$\rho_{XY} = \frac{\sigma_{XY}^2}{\sigma_X \sigma_Y} \quad (11)$$

Na grande maioria das plantas industriais modernas, o principal método adotado para reduzir a variabilidade é o controle automático de processos, seja por meio de controladores *feedforward* ou *feedback*. Conforme Johnson e Bagshaw (1974), Harris e Ross (1991), Padgett *et al.* (1992), Gujarati (2004), Psakis e Papaleonida (2007), em função deste tipo de controle efeitos da auto-correlação estão presentes na maioria dos processos industriais contínuos e em batelada, de maneira que o valor de um determinado parâmetro monitorado depende do seu valor passado. Essa característica é muito comum, por exemplo, em indústrias de papel e celulose, alimentos, produtos químicos, petroquímicos, dentro outras. De acordo com Macgregor (1990) e Wiel *et al.* (1992), a auto-correlação induz um caráter determinístico ao processo, sugerindo a possibilidade de compensações de efeitos por meio de manipulação de variáveis. Segundo Box *et al.* (1994), a função de auto-correlação, ou correlação cruzada, mede o grau de correlação de uma variável em um dado instante consigo mesma, em um instante de tempo posterior ou anterior. Esse fator permite, por exemplo, que se analise o grau de irregularidade de um sinal.

Sob o ponto de vista dos alarmes, Wang *et al.* (2015) destacaram que a análise de correlação entre dois alarmes pode ser realizada usando um modelo de janela deslizante, em que o horário de início e fim da janela devem ser definidas, mas não fixadas. Como

as variáveis de processo variam no tempo, uma janela deslizante permiti atualizar os dados temporais e computar melhor a semelhança oportuna. A Figura 9 apresenta um exemplo de janela deslizante para análise de correlação de alarmes. Observa-se que, para o caso apresentado, os alarmes apresentam comportamento idêntico dentro da janela, o que significa elevado nível de correlação entre estes sinais.

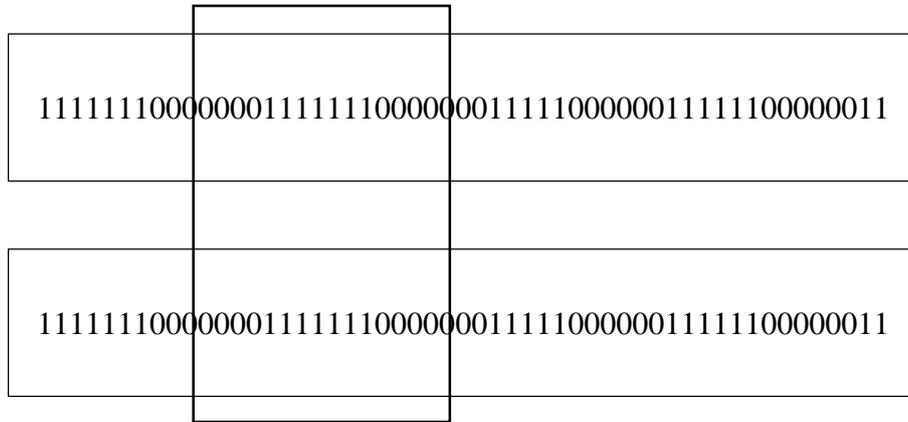


Figura 9. Exemplo de janela deslizante para análise de correlação de alarmes (Adaptado de Wang *et al.*, 2015).

Em função das características de propagação, dois alarmes, em que um deles é ativado como consequência do outro, em geral são ativados com um atraso de tempo. Este efeito enfraquece a correlação entre estes alarmes, a despeito da relação de causa e consequência. Portanto, é pertinente estimar o intervalo de tempo característico entre a ação destes dois alarmes. Tradicionalmente, as funções de auto-correlação, ou correlação cruzada (*cross-correlation dunctions* – CCF), são usadas para estimar o atraso no coeficiente de correlação máxima entre as duas sequências de alarme (LAI e TORP, 1999; YANG, SHAH e XIAO, 2010). Considerando duas sequências de alarme X_{pj} e X_{qj} , com média μ_{xp} e μ_{xq} e variância σ^2_{xp} e σ^2_{xq} , respectivamente, e supondo um atraso de tempo, k , a função de correlação cruzada, ϕ_{xpXq} , pode ser calculada pela Equação (12).

$$\phi_{xpXq}(k) = \frac{1}{N - k} \sum_{j=1}^{N-k} \frac{(X_{pj} - \mu_{xp})(X_{qj+k} - \mu_{xq})}{\sigma^2_{xp} \sigma^2_{xq}} \quad (12)$$

A análise de correlação entre alarmes permite obter informações preciosas sobre o comportamento conjunto das variáveis de processo. Talvez por conta disso, este é um

tema muito abordado na literatura. Por exemplo, Noda (2012) discutiu duas abordagens para avaliar o desempenho de sistemas de alarmes em plantas industriais. A primeira abordagem utiliza a correlação de eventos para detectar semelhanças estatísticas entre séries temporais de dados de alarme e eventos da operação, de forma que o agrupamento de eventos correlacionados torna mais fácil a redução do número de alarmes gerados com maior frequência. A segunda abordagem usa um modelo para imitar falhas humanas na detecção de alarmes. Kondaveeti *et al.* (2010 a/b) utilizou o coeficiente de similaridade de Jaccard para identificar alarmes correlacionados.

Xie *et al.* (2006) apresentaram uma abordagem estatística multivariada para detectar e diagnosticar falhas em plantas industriais com dinâmicas complexas. O trabalho destacou as dificuldades para o monitoramento de variáveis correlacionadas, avaliando o impacto da auto-correlação sobre o nível de significância dos testes de hipóteses estatísticas. Estes tipos de correlações podem se manifestar na forma de falsos alarmes ou levar a monitoramentos insensíveis. Lieftucht *et al.* (2006) propuseram alguns métodos estatísticos multivariados para remover a auto-correlação e a correlação cruzada entre variáveis de processo, reduzindo a quantidade de falsos alarmes. A eficácia dos métodos apresentados foi avaliada com auxílio de exemplos uni e multivariados simulados, bem como em uma unidade industrial.

Higuchi *et al.* (2009) avaliaram a correlação de eventos em uma planta de eteno com o objetivo de reduzir o número de alarmes gerados na unidade. O método elaborado permitiu detectar semelhanças estatísticas entre as ocorrências distintas de alarmes e agrupar eventos correlacionados com base no grau de semelhança. Os resultados foram úteis para identificar alarmes desnecessários, como alarmes sequenciais e alarmes ruidosos. Nishiguchi e Takai (2009) utilizaram um novo método para a melhoria do desempenho de sistemas de alarmes por meio da análise de correlação de eventos. A validação do método foi obtida por meio de um estudo de caso industrial, mostrando que é possível melhorar a segurança do processo, a produtividade do processo, e simultaneamente padronizar as ações dos operadores.

Nishiguchi e Takai (2013) propuseram um novo método para melhorar o desempenho de sistemas de alarmes por meio da análise de correlação de eventos. A validação do método foi realizada com auxílio de um estudo de caso industrial, mostrando que é possível melhorar a segurança do processo, a produtividade do processo, assim como padronizar as ações dos operadores. Amin (2012) propôs o uso do Mapa de Cores de Similaridade de Alarmes (*Alarm Similarity Color Map – ASCM*) para detectar alarmes

correlacionados. Neste tipo de gráfico, as variáveis correlacionadas são indicadas em um mapa bidimensional em colorações mais intensas, ao passo que as variáveis com baixa correlação são ilustradas com colorações mais claras. Esta forma de apresentação permite identificação mais amigável das correlações, quando comparada com a forma de tabelas, principalmente quando se trabalha com grandes conjuntos de dados.

2.5. Análise de Agrupamentos

Apesar da Análise de Correlação constituir uma técnica multivariada, ela só permite realizar comparações em pares, o que a torna limitada quando o objetivo é monitorar o processo multivariável como um todo. Como as variáveis observadas apresentam necessariamente associações, devido à resposta a um conjunto comum de fenômenos envolvidos no processo, o uso de um modelo estatístico de associação, ao invés do uso da média das observações, pode ser mais interessante. É neste sentido em que a Análise de Agrupamentos (AA) é proposta nesta seção.

A Análise de Agrupamentos, do inglês *Cluster Analysis*, é uma técnica multivariada cuja finalidade é agregar objetos com base nas características comuns que eles possuem. O resultado é a definição de grupos que exibem máxima homogeneidade de objetos dentro dos grupos e, ao mesmo tempo, máxima heterogeneidade entre eles. Este tipo de análise estuda todo um conjunto de relações interdependentes e não faz distinção entre variáveis dependentes e independentes. Alguns métodos estão calcados nos cálculos de distância. Portanto, não requerem qualquer conhecimento estatístico para a aplicação. O uso mais tradicional da análise de agrupamentos tem fins exploratórios, com o objetivo de taxonomia (classificação de objetos baseada na experiência).

A formulação do problema é considerada a parte mais importante de uma Análise de Agrupamentos. A inclusão de variáveis sem importância para o comportamento do conjunto pode distorcer o resultado final da análise. Por isto, a Análise de Agrupamentos é muito sensível à presença de *outliers* (MEYER, 2002). Ao analisar os dados, deve-se verificar se as variáveis medidas possuem unidades muito diferentes entre si, já que a solução por aglomerado pode ser influenciada pelas unidades de medida. Recomenda-se uma etapa preliminar de padronização dos dados, caso necessário, fazendo com que as variáveis apresentem contribuição similar para o cálculo do coeficiente de similaridade entre os objetos.

De acordo com Vicini (2005), as etapas normalmente envolvidas em uma Análise de Agrupamentos estão apresentadas na Figura 10. Estas etapas não são independentes e,

algumas vezes, é necessário voltar à etapa anterior para corrigir e aprimorar algumas etapas posteriores. Inicialmente faz-se necessária a formulação do problema, com a definição dos objetivos a serem alcançados na análise. Deve-se verificar se o foco é o padrão ou a proximidade. Se o foco for o padrão, então pode-se utilizar medidas de correlação para identificar similaridade. Se o foco for a proximidade, então pode-se optar pelas medidas de distâncias para identificar a similaridade. Posteriormente, deve-se fazer o tratamento dos dados com a padronização dos mesmos, caso isto seja realmente necessário.

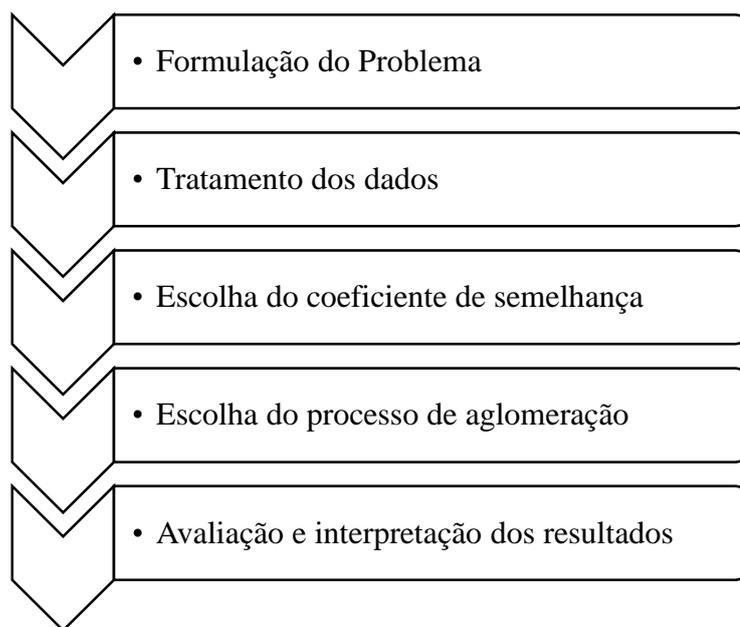


Figura 10. Etapas envolvidas em uma análise típica de agrupamentos (Adaptado de Vicini, 2005).

A escolha do coeficiente de semelhança é a etapa seguinte, em que se escolhe o método de estimação da medida de similaridade ou dissimilaridade entre os indivíduos ou populações a serem agrupados. Na medida de similaridade, quanto maior for o valor observado, mais parecido serão os objetos. Já na medida de dissimilaridade, quanto maior for o valor observado, menos parecido serão os objetos. Um exemplo de medida de similaridade é o coeficiente de correlação, pois quanto maior é esse valor, maior é a associação. Um exemplo de medida de dissimilaridade é a distância euclidiana, pois quanto menor o valor mais próximo os objetos estão uns dos outros. A utilização de diferentes medidas de distância pode levar a resultados diferentes de aglomeração, portanto, é conveniente utilizar medidas diferentes e comparar os resultados para utilizar a medida mais adequada na análise. A próxima etapa consiste na escolha do método de

aglomeração, em que os dados são agrupados conforme suas semelhanças. A decisão sobre o número total de conglomerados a constarem na análise cabe ao pesquisador, pois depende dos objetivos perseguidos em cada pesquisa.

Conforme discutido por Malhotra (2001), o resultado final de uma Análise de Agrupamento é apresentado na forma de um dendograma, que pode ser representado na forma horizontal ou vertical. Na forma horizontal, o eixo y representa os grupos unidos por ordem decrescente de semelhança, enquanto o eixo x indica as distâncias entre os grupos que foram formados. O dendograma é lido de cima para baixo.

A Figura 11 mostra um exemplo de um dendograma horizontal. Verifica-se que as variáveis Var1 e Var5 são as que possuem a maior semelhança no dendograma, por apresentarem a menor distância euclidiana, sendo essas a formarem o primeiro grupo. Logo em seguida vêm as variáveis Var2, Var3, Var8, e, assim, sucessivamente. As variáveis devem ser agrupadas, por ordem decrescente de semelhança. Ou seja, a variável Var9 forma o último grupo do dendograma, distinto dos demais grupos formados pelo fato dessa variável apresentar pouca semelhança com as demais.

A Figura 12 mostra um exemplo de um dendograma vertical. A leitura é feita da direita para esquerda, sendo que o eixo y indica as distâncias entre os grupos formados e o eixo x representa os grupos unidos por ordem decrescente de semelhança. A interpretação é análoga à da Figura 11 mudando apenas o eixo em que as variáveis estão representadas.

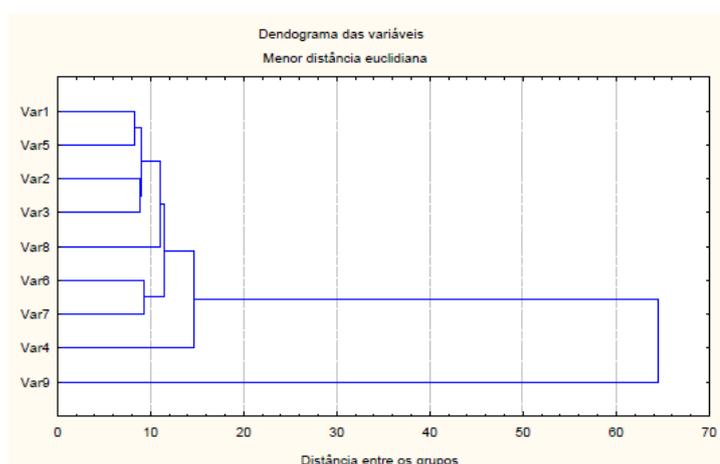


Figura 11. Exemplo de dendograma horizontal (VICINI, 2005).

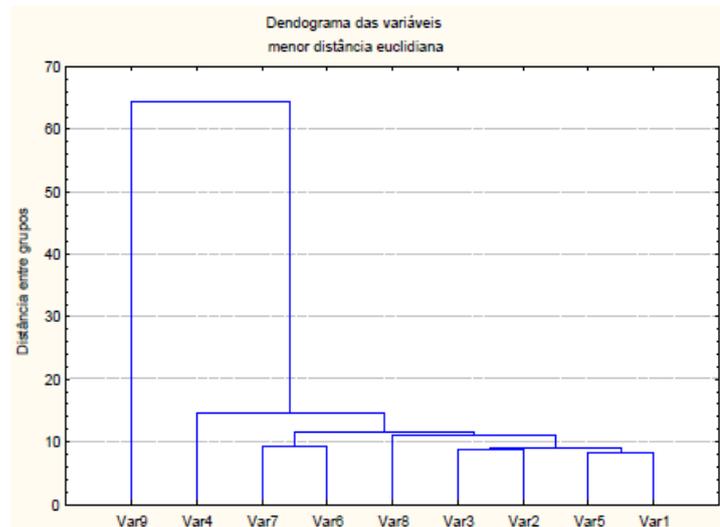


Figura 12. Exemplo de dendrograma horizontal (VICINI, 2005).

As distâncias são as medidas de dissimilaridade mais utilizadas no estudo de bancos de dados com variáveis quantitativas. Por definição, a distância entre dois pontos sempre é um número positivo, sendo igual a zero apenas no caso específico em que os pontos coincidem. Além disso, a distância medida de um ponto P_1 até um ponto P_2 deve ser a mesma, quer essa medida seja feita de P_1 para P_2 , ou de P_2 para P_1 . As métricas apresentadas a seguir foram obtidas de Vicini (2005) e expressam as principais medidas de distância que podem ser utilizadas na Análise de Agrupamentos.

- Distância Euclidiana

É provavelmente o tipo de distância mais comumente escolhido, em função da simplicidade. A Equação (13) apresenta a forma mais comum para calcular a distância euclidiana entre dois pontos.

$$d(X_i, X_k) = \sqrt{\sum_{j=1}^p (X_{ij} - X_{kj})^2} \quad (13)$$

- Distância de Manhattan

Os resultados deste procedimento são semelhantes à distância euclidiana, com a vantagem de que grandes diferenças são reprimidas por não se elevar os resultados ao quadrado. A Equação (14) apresenta a forma mais comum para se calcular a distância de Manhattan entre dois pontos.

$$d(X_i, X_k) = \sum_{j=1}^p |X_{ij} - X_{kj}| \quad (14)$$

- Distância de Chebychev

Esta medida de distância é apropriada em casos em que se quer definir dois objetos como diferentes se eles são diferentes em qualquer uma das dimensões. A Equação (15) apresenta a forma mais comum para se calcular a distância de Chebychev entre dois pontos.

$$d(X_i, Y_j) = \text{Máximo}|X_i - Y_j| \quad (15)$$

- Distância de Minkowski

Algumas vezes tem-se o interesse de ponderar progressivamente, em forma crescente ou decrescente, objetos que são muito diferentes quando alocados em certas dimensões. A Equação (16) apresenta a forma mais comum para se calcular a distância de Minkowski entre dois pontos.

$$d(X_i, X_k) = \left(\sum_{j=1}^n |X_i - X_k|^p \right)^{1/p} \quad (16)$$

- Medida de Correlação Inversa

Esta é uma medida de similaridade. Porém, ao se fazer $1 - r_{\text{Pearson}}$, obtém-se uma medida de dissimilaridade. A Equação (17) apresenta a forma mais comum usada para se calcular a medida de correlação inversa entre dois pontos.

$$d(X, Y) = 1 - \sum_{i=1}^n (X_i - \mu_X)(Y_i - \mu_Y) \left[\sqrt{\sum_{j=1}^p (X_j - \mu_X)^2} \sqrt{\sum_{j=1}^p (Y_j - \mu_Y)^2} \right]^{-1} \quad (18)$$

A escolha do método de agrupamento depende da correta classificação de uma amostra estar dentro de um novo grupo ou de outro que já tenha sido formado. Há grande quantidade de métodos de agrupamento disponíveis na literatura. De uma maneira geral, estas técnicas podem ser classificadas em hierárquicas e não hierárquicas. A aglomeração

hierárquica, como o próprio nome indica, caracteriza-se pelo estabelecimento de uma hierarquia (estrutura em forma de árvore), sendo esta a mais utilizada. Estes métodos podem ser divididos em aglomerativos e divisivos.

O agrupamento aglomerativo tem início em um grupo separado e formam-se novos grupos maiores, reunindo os objetos. O processo continua até que todos os objetos tenham sido analisados. O método é sequencial, de maneira que os objetos são reunidos, um após o outro, respeitando uma determinada sequência de aglomeração. O critério básico da fusão entre um objeto e um grupo, ou entre dois grupos, é sempre o mesmo. A seguir são apresentados os principais métodos aglomerativos (VICINI, 2005):

- Método do vizinho mais próximo (*Single Linkage*)

Baseia-se na distância mínima, ou regra do vizinho mais próximo. Os dois primeiros objetos agrupados são os que apresentam menor distância entre si. Identifica-se a menor distância agrupando-se o terceiro objeto com os dois primeiros, ou formando um novo grupo de dois objetos. Em cada estágio, a distância entre dois grupos é definida como a distância entre seus dois pontos mais próximos. Dois grupos podem incorporar-se em cada estágio por meio do encadeamento mais curto entre eles. Continua-se o processo até que todos os objetos estejam em um único grupo.

- Método do vizinho mais longe (*Complete Linkage*)

É semelhante ao método do vizinho mais próximo, embora se baseie na distância máxima entre os objetos ou o método do vizinho mais afastado. Neste, a distância entre dois grupos é calculada entre seus dois pontos mais afastados.

- Método de Ward

Busca-se gerar grupos que possam minimizar a variância dentro destes grupos. O método minimiza o quadrado da distância euclidiana às médias dos grupos. Um grupo é reunido a um outro se essa reunião proporcionar o menor aumento da variância intra-grupo. Este método de variância calcula as médias de todas as variáveis para cada grupo, escolhendo a que proporciona a menor variância. Calcula-se então, para cada objeto o quadrado da distância euclidiana e as médias do agrupamento. Somam-se então essas distâncias para todos os objetos. Em cada estágio, combinam-se os dois grupos que apresentaram um menor aumento na soma global de quadrados dentro dos agrupamentos. O Método de Ward é atraente por ser baseado numa medida com forte apelo estatístico e

por gerar grupos que, assim como no do método do vizinho mais longe, apresentaram alta homogeneidade interna.

- Método do encadeamento médio

É semelhante aos métodos anteriores, embora a distância entre dois grupos seja definida como a média da distância entre todos os pares de objetos, em que cada membro de um par provém de cada um dos grupos. No método de encadeamento médio, são utilizadas informações sobre todos os pares de distâncias, e não apenas da distância mínima ou máxima.

- Método do centróide

Considera que a distância entre dois aglomerados é a distância entre seus centróides, que nada mais é que a média para todas as variáveis. A cada agrupamento novo de objetos, deve-se calcular um novo centroide.

Após calcular as distâncias entre os objetos e vinculá-los a um grupo específico, é preciso avaliar a eficácia do método utilizado. Uma maneira de medir a validade da metodologia utilizada é comparar o resultado obtido após o agrupamento com os dados originais. Agrupamentos válidos implicam em forte correlação, também chamada de coeficiente de correlação cofenética. Portanto, quanto mais próximo de 1 for este valor, melhor é o resultado de *cluster* (VICINI, 2005).

2.6. Análise de Componentes Principais

A Análise de Componentes Principais (ACP), do inglês *Principal Component Analysis* (PCA), é uma técnica de análise multivariada que possibilita investigações com um grande número de dados disponíveis. O desenvolvimento da técnica de PCA foi conduzido, em parte, pela necessidade de analisar conjuntos de dados com muitas variáveis correlacionadas. De acordo com Vicini (2005), a técnica de PCA é muito utilizada para a redução da dimensionalidade dos dados, já que é possível trabalhar apenas com as variáveis com maiores variabilidades associadas. Muitas vezes, pode-se chegar a conjuntos não correlacionados de variáveis, de modo que é possível confirmar grupos formados em uma Análise de Agrupamentos. O PCA depende somente da matriz de covariância e não exige qualquer suposição sobre a forma da distribuição multivariada

das variáveis envolvidas na análise. Se o comportamento normal ocorre a análise é fortalecida, caso contrário, ela ainda vale a pena.

Conforme apresentado por Feital (2011), o objetivo do PCA é tomar p variáveis X_1, X_2, \dots, X_p e encontrar combinações destas para produzir índices Z_1, Z_2, \dots, Z_p que sejam não correlacionados na ordem de sua importância e que descrevam a variação nos dados. A falta de correlação significa que os índices estão medindo diferentes "dimensões" dos dados. A ordem proposta é tal que $\text{Var}(Z_1) > \text{Var}(Z_2) > \dots > \text{Var}(Z_p)$, em que $\text{Var}(Z_1)$ denota a variância de (Z_1) , $\text{Var}(Z_2)$ denota a variância de (Z_2) e assim sucessivamente. Os índices Z são então os componentes principais. Uma análise de componentes principais começa com dados de p variáveis para n indivíduos. O primeiro componente principal é então a combinação linear das variáveis X_1, X_2, \dots, X_p , conforme mostram as Equações (18), (19) e (20) apresentadas a seguir:

$$Z_1 = a_{11}X_1 + a_{12}X_2 + \dots + a_{1p}X_p \quad (18)$$

$$Z_2 = a_{21}X_1 + a_{22}X_2 + \dots + a_{2p}X_p \quad (19)$$

⋮

$$Z_n = a_{n1}X_1 + a_{n2}X_2 + \dots + a_{np}X_p \quad (20)$$

Assim, $\text{Var}(Z_1)$, a variância de Z_1 , é tão grande quanto possível, dada a restrição sobre as constantes a_{ij} , representadas pelas Equações (21), (22) e (23). Esta restrição é introduzida porque, se isto não for feito, $\text{Var}(Z_1)$ pode ser aumentada fazendo simplesmente crescer qualquer um dos valores a_{ij} . Além disso, os componentes principais Z_1, Z_2, Z_n devem ter correlação zero para todos os dados. Se existem p variáveis, então existirão no máximo p componentes principais.

$$a_{11}^2 + a_{12}^2 + \dots + a_{1p}^2 = 1 \quad (21)$$

$$a_{21}^2 + a_{22}^2 + \dots + a_{2p}^2 = 1 \quad (22)$$

⋮

$$a_{n1}^2 + a_{n2}^2 + \dots + a_{np}^2 = 1 \quad (23)$$

A Análise de Componentes Principais envolve o cálculo dos autovalores de uma matriz de covariâncias amostral. Esta matriz é simétrica e tem a forma da Equação (24), em que o elemento C_{ii} na diagonal principal é a variância de X_i e o termo fora da diagonal principal C_{ij} é a covariância entre as variáveis X_i e X_j .

$$C = \begin{pmatrix} C_{11} & C_{12} & C_{13} & \dots & C_{1n} \\ C_{21} & C_{22} & C_{23} & \dots & C_{2n} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ C_{n1} & C_{n2} & C_{n3} & \dots & C_{nn} \end{pmatrix} \quad (24)$$

As variâncias dos componentes principais são os autovalores da matriz C . Existem p destes autovalores, alguns dos quais podem ser iguais a zero. Autovalores negativos não são possíveis para uma matriz de covariância. Admitindo que os autovalores estão ordenados como $\lambda_1 > \lambda_2 > \dots > \lambda_n$, então i corresponde ao i -ésimo componente principal. Uma propriedade importante dos autovalores é que a soma deles é igual à soma dos elementos da diagonal (o traço) da matriz C , conforme mostrado na Equação (25).

$$\lambda_1 + \lambda_2 + \dots + \lambda_n = C_{11} + C_{22} + \dots + C_{nn} \quad (25)$$

Deve ser observado que C_{ii} é a variância de X_i e que λ_i é a variância de Z_i . Isto significa que a soma das variâncias dos componentes principais é igual à soma das variâncias das variáveis originais. Portanto, os componentes principais contam com toda a variação nos dados originais. Para evitar que as diferentes unidades de engenharia, que podem estar associadas às variáveis analisadas, influenciem o cálculo dos componentes principais, é usual padronizar as variáveis $X_1, X_2; \dots, X_p$ para terem médias 0 e variâncias 1. Como na Equação 5, a padronização das medidas assegura que todas as variáveis tenham o mesmo peso durante a análise. Além disso, a matriz de covariâncias para as variáveis padronizadas é a própria matriz de correlações.

Conforme apresentado por Feital (2011), a técnica de PCA está fundamentada nas seguintes hipóteses: i) admite que a dependência entre as variáveis é linear; ii) as variáveis observadas não apresentam auto-correlação, o que permite que a ordem das observações nas sequências dos dados seja irrelevante; iii) os dados seguem a distribuição normal de probabilidades; iv) admite a invariabilidade de propriedades estatísticas por todo o espaço

geométrico das variáveis. Na literatura, alguns trabalhos foram propostos com o objetivo de contornar estas limitações. Por exemplo, para solucionar o problema do uso limitado do modelo PCA para processos lineares, pode-se consultar os trabalhos de Kramer (1991), Dong e McAvoy (1996), Schölkopf *et al.* (1998), entre outros. Como a técnica admite associação temporal dos dados nula, sua aplicação em processos dinâmicos torna-se prejudicada. Alternativas de PCA dinâmico podem ser encontradas em Wold (1994), Ku (1995), Li *et al.* (2000), Wang *et al.* (2005), entre outros. O uso da técnica de PCA com dados oriundos de uma distribuição de probabilidade não normal pode ser encontrado em Comon (1994), Tipping e Bishop (1999) e outros.

Para gerar cartas de controle semelhantes às cartas univariadas, algumas estatísticas podem ser utilizadas, com o auxílio de um modelo PCA para o processo. Hotelling foi um dos primeiros a analisar variáveis correlacionadas sob uma perspectiva de controle estatístico, utilizando como base um procedimento multivariado. A estatística T^2 de Hotelling está baseada na variabilidade dos componentes principais. Portanto, ela indica se os dados estão em concordância com o modelo. Esta estatística testa, por meio do teste F, a igualdade das variâncias (corrente e registrada) dos componentes principais. A estatística T^2 pode ser calculada conforme mostra a Equação (26) e o Limite de Controle Superior da Equação (27). Para um gráfico multivariado, os limites de controle são dados pela escolha de um valor α , tal que $P(T^2 \leq LIC) = 1$ (HOTELLING, 1947; CHIANG, RUSSELL e BRAATZ, 2000; QIN, 2003).

$$T^2 = (X_k - \bar{X})'S^{-1}(X_k - \bar{X}) \quad (26)$$

$$T_{\max}^2 = \frac{n_t(n_k^2 - 1)}{n_k(n_k - n_t)} F_{\alpha}(n_k, n_k - n_t) \quad (27)$$

Para os limites mostrados acima, n_t é o número de componentes escolhidos, n_k representa as observações para compor e gerar o modelo, F_{α} é o percentil da distribuição F com n_t e $n_k - n_t$ graus de liberdade e tolerância α , \bar{X} é a estimativa para o vetor das médias e S a estimativa para o vetor de covariância do processo. Portanto, a Equação (25) é uma relação oriunda das hipóteses de normalidade da variação dos sinais e de

amostragem suficientemente grande, admitindo-se que médias e covariâncias populacionais podem ser estimadas dos dados.

2.7. Considerações Finais

Neste capítulo listaram-se os principais problemas que normalmente se fazem presentes nos sistemas de alarmes das plantas industriais, bem como alguns indicadores de desempenho que podem ser usados para aferir a qualidade desses sistemas. Na literatura existem diversas técnicas estatísticas que podem ser utilizadas para identificar problemas em sistemas de alarmes. No entanto, estas ferramentas são aplicadas de forma individual para identificar problemas específicos como, por exemplo, a presença de alarmes ruidosos, avalanche de alarmes e alarmes correlacionados. O próximo capítulo pretende sistematizar um protocolo de gerenciamento de alarmes, através do uso ordenado de técnicas estatísticas de análise de dados, capaz de orientar o operador durante as etapas do processo de tomada de decisão.

Durante a elaboração deste texto não foi evidenciado nenhum outro trabalho envolvendo a aplicação da análise de agrupamentos e de componentes principais para avaliar o comportamento de dados de alarmes. Desta forma, o próximo capítulo também busca investigar este campo de aplicação. A ideia central é comparar as correlações existentes entre as variáveis do processo e as correlações existentes entre os sinais de alarmes correspondentes. Se estas correlações se fazem presentes, então, pode-se propor o uso dessas ferramentas para simplificar o sistema de alarmes, reduzindo o número de pontos de alarmes ainda na fase de configuração desses sistemas.

3. ESTUDO DE CASO REAL

Conforme apresentado no capítulo anterior, existem diversos tipos de problemas que podem ocorrer em um sistema de alarmes. Identificar os tipos e a dimensão dos problemas é condição *sine qua non* para o início de um gerenciamento de alarmes. Este capítulo apresenta os resultados obtidos com a implementação de um protocolo de gerenciamento de alarmes que utiliza técnicas estatísticas de análise de dados de forma ordenada para detectar e diagnosticar alarmes potencialmente problemáticos. O algoritmo proposto foi implementado em uma Unidade de Processamento de Gás Natural. Os dados de alarmes apresentados a seguir foram obtidos diariamente durante o período compreendido entre 01/01/2013 à 31/12/2015 (3 anos).

3.1. Metodologia Aplicada ao Estudo de Caso Real

A metodologia apresentada nesta secção propõe o uso do ciclo de gestão de gerenciamento apresentado na Figura 13. O caráter inovador, no entanto, está inserido dentro de etapa de “Identificação” com o uso sequencial e ordenado de técnicas estatísticas de análise de dados, dentre elas, a análise de frequência, diagrama de Pareto, análise de ocorrência, mapas de cores, análise de agrupamentos e análise de componentes principais. A proposta consiste não apenas em reduzir o número de ocorrências de alarmes na planta, mas também subsidiar o processo de tomada de decisão em situações que envolvam a simplificação do sistema de alarmes com eventuais exclusões de pontos a serem monitorados.

O protocolo de gerenciamento de alarmes proposto inicia-se com a identificação de pontos de melhorias no sistema de alarmes ou alarmes potencialmente problemáticos. Estes alarmes são racionalizados, buscando evidenciar a sua importância para a operação da unidade e se são necessários ajustes nos parâmetros (*setpoint, deadband, delay time, filtering* etc). Formulada a hipótese inicial, as propostas de melhorias são direcionadas a etapa de gestão de mudanças, onde práticas de *brastorming* são realizadas com equipe multidisciplinar (segurança, instrumentação, automação, processos *etc*). Nesta etapa, todas as ações a serem realizadas na planta são submetidas a um procedimento de análise preliminar de riscos, documentadas, assinadas e arquivadas. O ciclo prossegue com a implementação da(s) mudança(s) e o monitoramento do desempenho do sistema de alarmes.



Figura 13. Ciclo de gerenciamento de alarmes (Adaptado de EEMUA, 2013).

A Figura 14 indica a localização do protocolo de gerenciamento de alarmes (PGA) dentro da pirâmide de automação. A camada inicial (base da pirâmide) é composta pela instrumentação de campo, o que inclui os sensores, transdutores, atuadores, entre outros dispositivos. A camada superior a esta envolve os controladores lógicos programáveis (CLP), computadores, controladores PID, protocolos de comunicação *etc.* Na terceira camada estão os sistemas supervisórios de controle e de aquisição de dados. O PGA localiza-se acima do sistema de controle e aquisição de dados (SCADA), fazendo uso destas informações e inserido no sistema integrado de gestão empresarial.



Figura 14. Localização do protocolo de gerenciamento de alarmes.

A Figura 15 apresenta o fluxograma principal do protocolo de gerenciamento de alarmes proposto neste trabalho para a identificação de pontos de melhoria. O algoritmo inicia-se com a coleta dos dados de ativação de alarmes da unidade, consultado o *log* de alarmes e eventos do Sistema Supervisório de Controle e Aquisição de Dados (SCADA). Utilizou-se intervalos semanais para a realização desta coleta de informações. Deve-se atentar para o fato de que janelas de tempo maiores (quinzenal, mensal *etc*) podem trazer pouco benefício em termos de solução imediata dos problemas enfrentados no sistema de alarmes da unidade. Por outro lado, janelas de tempo muito curtas (dia, horas, minutos *etc*) podem dificultar a percepção de problemas sistêmicos no processo.

Normalmente, os sistemas SCADA oferecem arquivos de *log* de alarmes e eventos em um formato pré-definido (BOYER, 1999). A partir deste formato é possível criar códigos computacionais específicos para realizar o tratamento inicial dos dados. Neste sentido foi elaborado um código em VBA-Excel® para organizar os dados de alarmes registrados no sistema SCADA sob diferentes formas de tabelas. O detalhamento destas tabelas será apresentado nas seções a seguir.

Após a coleta e tratamento inicial dos dados de alarmes, a primeira estatística proposta no algoritmo é a análise de frequência, cujo objetivo é identificar, dentro da janela semanal, os dias de maior instabilidade do sistema de alarmes. Considera-se como sistema instável período com taxa de ocorrência média superior a 144 ativações. Este valor representa o somatório de todas as *tags* de alarmes. A instabilidade do sistema de alarmes direciona o protocolo para a análise de Pareto, caso contrário, o procedimento é finalizado.

A etapa seguinte utiliza o diagrama de Pareto para identificar dentro do(s) dia(s) de maior instabilidade aquelas *tags* de alarmes que mais contribuíram para elevar a taxa de ativação na planta. Para isto, faz-se a totalização do número de ocorrências de cada *tag* de alarme e as organiza de forma decrescente. Feito isto, verifica-se se existem *tags* de alarmes com mesmo número de ocorrências.

A análise de ocorrência tem por finalidade identificar redundância de informação no sistema de alarmes. Se o comportamento das *tags* forem iguais, então suspeita-se da existência de alarmes redundantes no sistema, conseqüentemente, estes sinais podem ser simplificados. A simplificação direciona o algoritmo para a etapa 1. O comportamento diferente das *tags* de alarmes não exclui a possibilidade de haver redundância de informação no sistema. Nestas situações, o algoritmo é direcionado para a etapa 2.

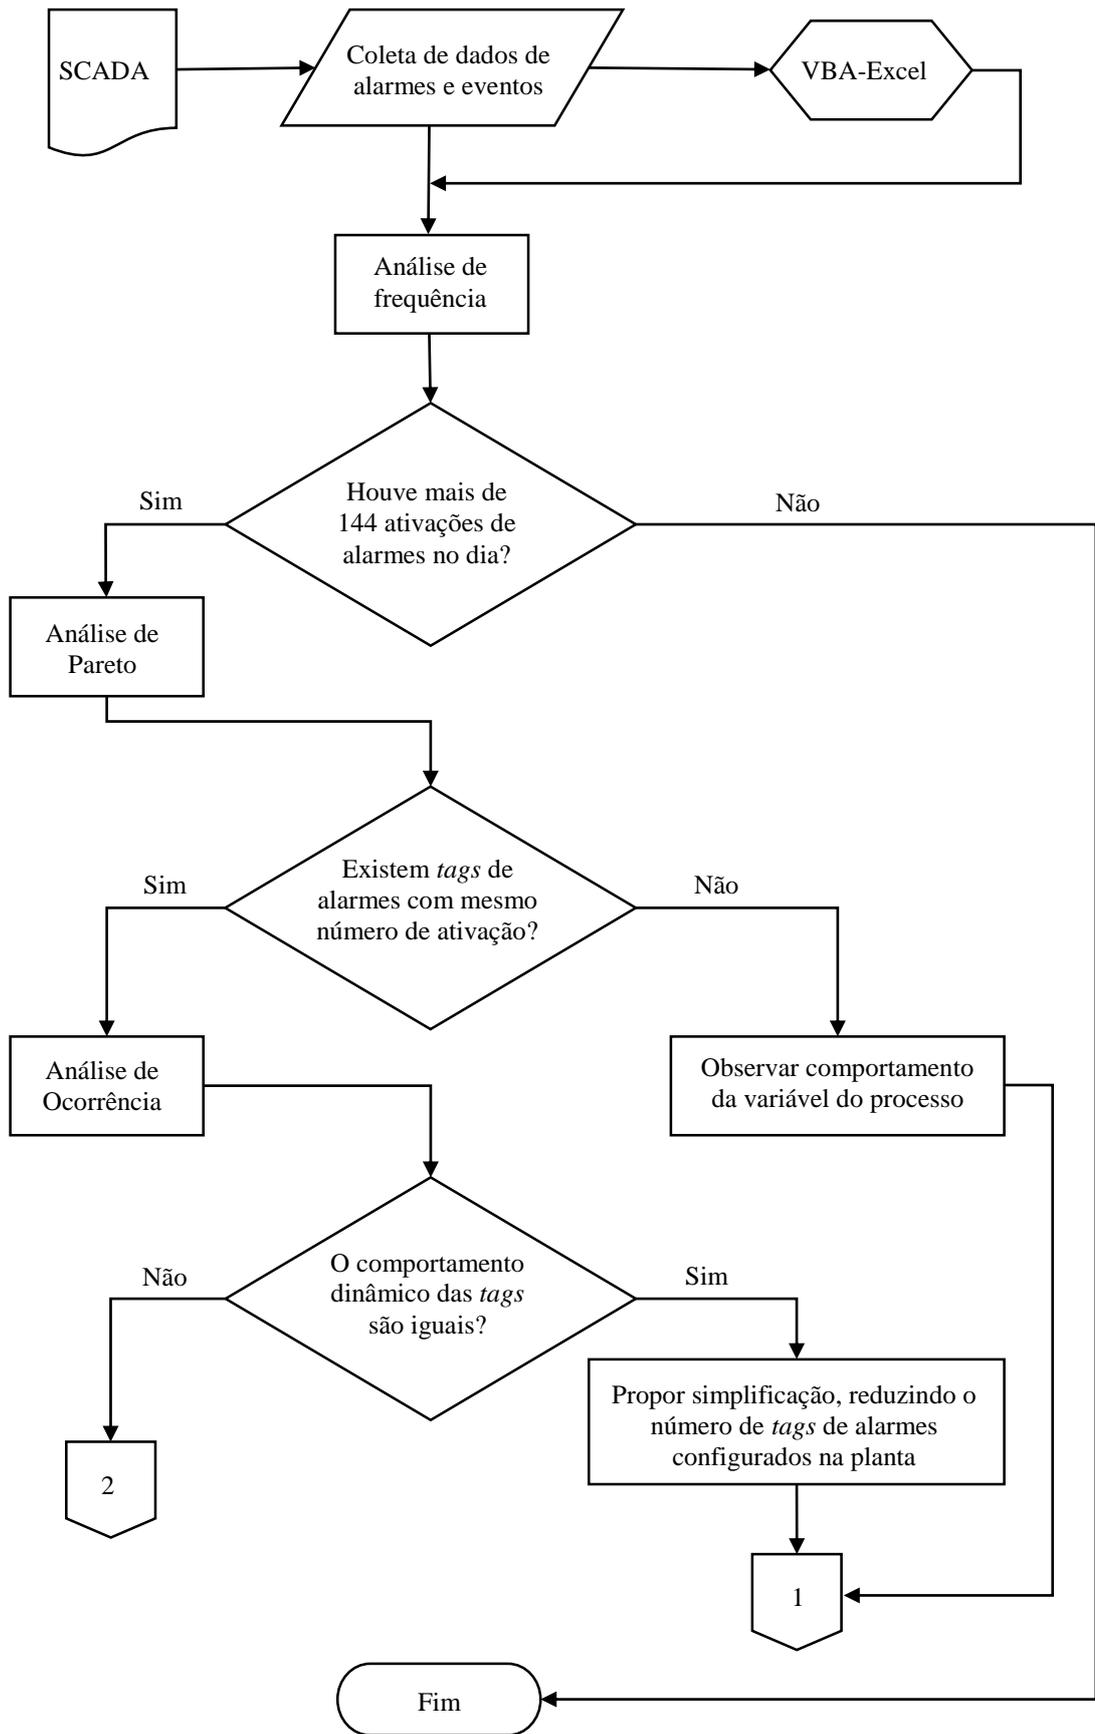


Figura 15. Fluxograma principal do protocolo de gerenciamento de alarmes.

A Figura 16 apresenta o fluxograma da etapa 1 do protocolo de gerenciamento de alarmes proposto neste trabalho. Esta fase inicia-se com o ajuste dos parâmetros do sistema de alarmes (*deadband*, *delay times* e *filtering*), conforme sugestões já apresentadas nas Tabelas 3, 4 e 5, respectivamente. O ajuste desses parâmetros é relativamente simples, tratando-se apenas de uma questão de configuração de *software*, de baixo custo e resulta numa redução significativa da taxa de ativação de alarmes.

O uso desses parâmetros sempre introduz tempo de atraso na detecção do sinal de alarme, mas, ainda assim vale a pena, pois o tempo de atraso (na ordem de segundos) introduzido com esses mecanismos é muito menor do que as dinâmicas envolvidas na planta (na ordem de minutos ou horas).

Após o ajuste dos parâmetros de configuração a etapa seguinte consiste em verificar se o valor do *setpoint* do alarme estava ou não próximo do ponto de operação. Caso negativo, suspeita-se da ocorrência de algum evento indesejável no processo, o que requer diagnóstico de falha(s) mais detalhado. As propostas de melhoria obtidas com a fase de diagnóstico devem obrigatoriamente passar pela etapa de gestão de mudanças.

As propostas de melhorias e as ações a serem implementadas após a fase da gestão de mudanças devem ser submetidas a uma Análise Preliminar de Riscos (APR), a fim de analisar o impacto das mesmas na unidade como um todo. Todas as alterações, bem como as pessoas responsáveis e os prazos estipulados para adequação devem ser registradas e devidamente arquivadas para fins de consultas futuras e eventuais auditoria.

Por outro lado, se o valor do *setpoint* do alarme estiver próximo do ponto de operação, então deve-se propor um novo ponto de atuação do alarme. Esta alteração também deve ser direcionada para a etapa de gestão de mudanças, APR e registro. O novo valor do *setpoint* de alarme deve ser estabelecido levando-se em consideração o comportamento desejável da variável do processo monitorada pelo alarme. Esta análise deve envolver aspectos de segurança operacional e de qualidade. Conforme já discutido neste trabalho, limites de atuação do alarme muito expansivos dificultam a percepção de falhas (ou desvios de operação), introduzindo risco adicional para a unidade.



Figura 16. Fluxograma da etapa 1 do protocolo de gerenciamento de alarmes.

A Figura 17 apresenta o fluxograma da etapa 2 do protocolo de gerenciamento de alarmes proposto neste trabalho. Esta parte do algoritmo busca identificar alarmes com comportamento dinâmico diferentes, mas que podem ser simplificados em função da redundância existente nas variáveis de processo associadas aos alarmes. A análise inicia-se com a aplicação do mapa de cores para identificar a existência ou não de correlações significativas entre as variáveis de processo. Se as variáveis apresentarem correlação significativa, deve-se propor simplificação das *tags* de alarmes, seguindo para as fases de gestão de mudanças, APR e registro.

A não identificação de correlação significativa pelo mapa de cores, não necessariamente implica da falta de correlação das variáveis de processo. Conforme já apresentado neste trabalho, o coeficiente de correlação calculado pelo mapa de cores é uma equação linear fundamentada na hipótese da distribuição normal de probabilidades. Estes dois pressupostos podem ser facilmente violados numa planta industrial. Por isto, propõe-se o uso da análise de *cluster* como ferramenta complementar para analisar a possível formação de grupos entre as variáveis de processo. Conforme já discutido, a análise de *cluster* é uma técnica não-linear e que não requer conhecimento a priori da distribuição de probabilidade.

Após a análise de *clusters* verifica-se se é possível agrupar as variáveis do processo com comportamento similar. Em caso negativo, o algoritmo é finalizado. Em caso positivo, o algoritmo é direcionado para a análise de componentes principais (PCA). O uso do PCA tem por finalidade verificar se os grupos identificados pela análise de *clusters* podem ser utilizados para simplificar as *tags* de alarmes em perda de informação relevante no processo. Conforme mencionado neste trabalho uma das características da análise de componentes principais é reduzir a dimensionalidade do sistema, mantendo o máximo de variabilidade original dos dados. Se o número de componentes principais for diferente do número de grupos identificado na análise de *clusters* o processo é finalizado.

Por outro lado, se o número de componentes principais for igual ao número de grupos identificado na análise de *clusters*, então há indícios suficientes para propor uma simplificação do número de *tags* de alarmes na planta. Neste caso, o fluxo de informações é novamente direcionado para a etapa 1, forçando novamente a análise dos parâmetros de configuração do sistema de alarmes e, caso necessário, o diagnóstico do processo. Este encadeamento de eventos faz com que todas as alterações realizadas no sistema de alarmes da unidade passem pelas fases de gestão de mudanças, APR e registro.

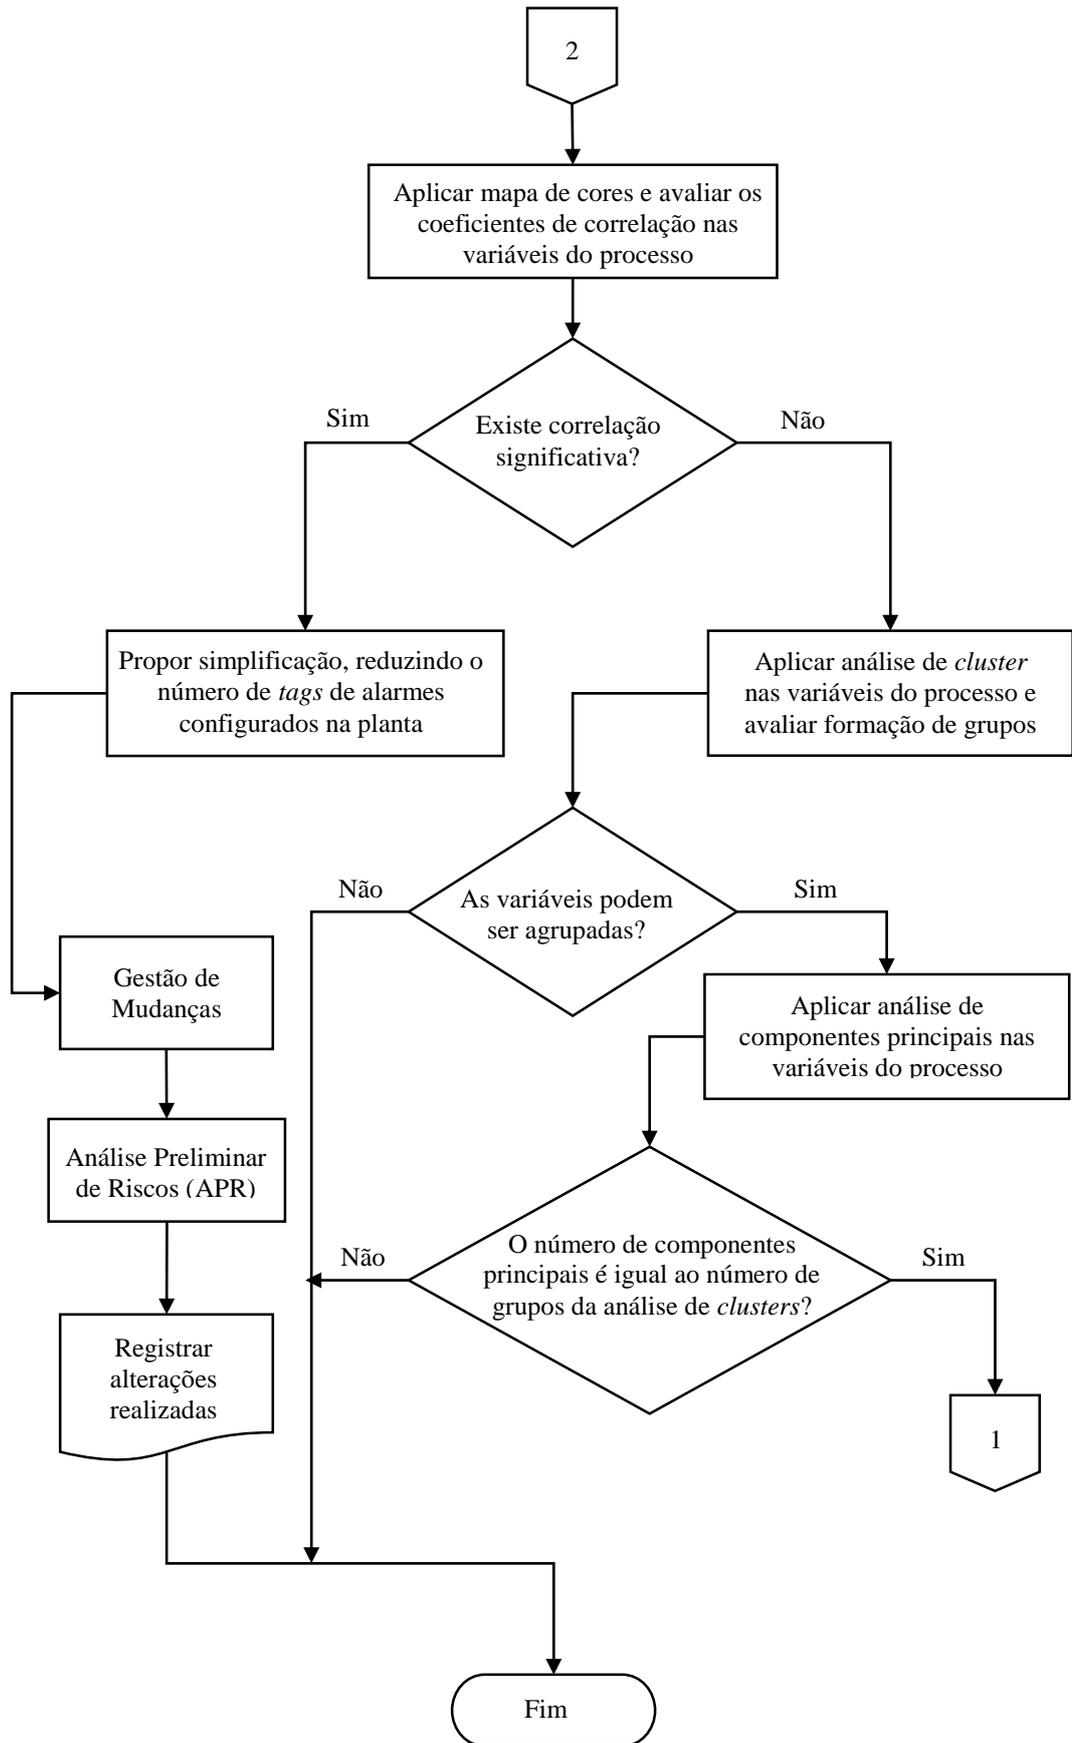


Figura 17. Fluxograma da etapa 2 do protocolo de gerenciamento de alarmes.

A seguir são apresentadas as formas estruturais das tabelas criadas via código VBA-Excel® para a aplicação da análise de frequência, análise de Pareto, análise de ocorrência, mapa de cores, análise preliminar de riscos, análise de cluster e análise de componentes principais, respectivamente.

- Análise de frequência

A Tabela 6 mostra a estrutura necessária para a realização da análise de frequência. Os dados apresentados nesta tabela são dados reais da planta obtidos durante o período compreendido entre os dias 01 e 07 de janeiro de 2013. Observa-se que para cada dia analisado é informado o número total de ativações de alarmes ocorridas na planta, bem como o limite máximo aceitável.

Tabela 6. Estrutura necessária para a realização da análise de frequência.

Dia	Total de ativações	Limite máximo aceitável
01/01/2013	370	144
02/01/2013	1.230	144
03/01/2013	659	144
04/01/2013	1.418	144
05/01/2013	359	144
06/01/2013	252	144
07/01/2013	351	144

A análise de frequência pode ser melhor compreendida pela Figura 18, obtida com auxílio do *software Microsoft Excel*®. As colunas representam o total de ocorrências de alarmes registrado em cada dia analisado, enquanto a linha vermelha tracejada indica o limite máximo aceitável (média de 144 ocorrências de alarmes por dia). Observa-se que em todos os dias o número de ativações de alarmes na planta foi maior do que o limite máximo aceitável, indicado grande instabilidade do sistema de alarmes e sugerindo oportunidades de melhorias.

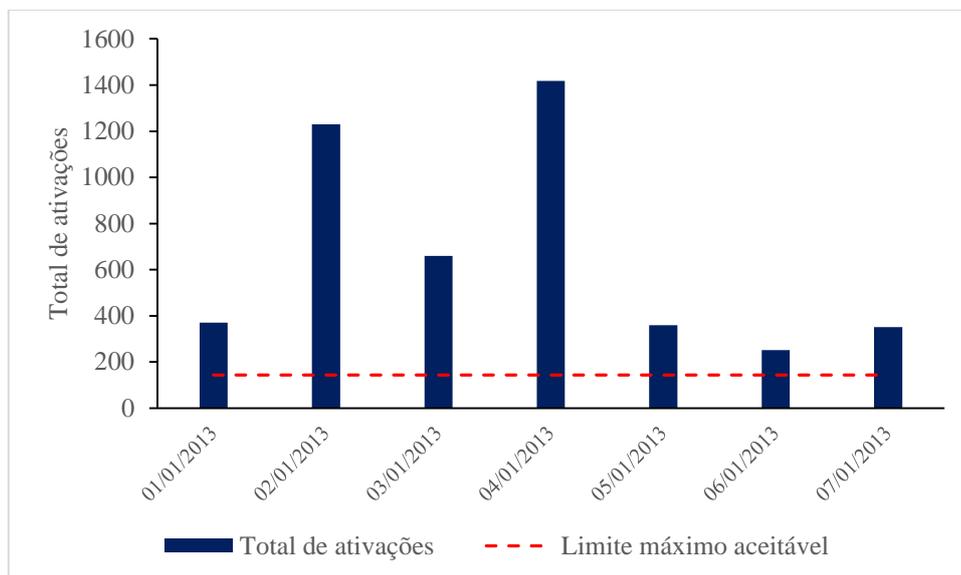


Figura 18. Resultado obtido com a análise de frequência.

- **Análise de Pareto**

Conforme Montgomery (2009), o diagrama de Pareto é um gráfico de barras verticais que apresenta os dados de forma a tornar evidente a priorização de temas, possibilitando concentrar os esforços de melhoria nos pontos que representam as melhores oportunidades, ou seja, onde os maiores ganhos podem ser obtidos. Ele utiliza o princípio conhecido como 80/20 onde 80% dos resultados corresponde a apenas 20% dos fatores, o que justifica a priorização. Os dados apresentados na Tabela 7 são dados reais obtidos da planta e mostram a estrutura necessária para a realização da análise de Pareto. Observa-se que as ocorrências de alarmes foram organizadas de forma decrescente, ou seja, da *tag* de alarme maior número de ativação para a *tag* de alarme com menor número de ativação.

A coluna “Frequência” indica a porcentagem que o número de ativação de uma determina *tag* de alarme representa com relação ao somatório total das ativações de alarmes registradas naquele dia. a quantidade total de ocorrências registradas no dia. A coluna “Frequência acumulada” mostra a porcentagem do número de ocorrências que de *tags* subsequentes. Por exemplo, o valor de 39,46% da *tag* LAL-31231851B1 é o somatório da frequência da *tag* PAL-31231818 (28,11%) com a frequência da *tag* LAL-3123101B1 (11,35%). Desta forma, nota-se que as 6 primeiras *tags* de alarmes já representam 74,59% do total de ativações registradas no dia 01/01/2013.

Tabela 7. Estrutura para a realização da análise de Pareto.

Dia	Tag do alarme	Nº ativações	Frequência	Freq. acumulada
01/01/2013	PAL-31231818	104	28,11%	28,11%
01/01/2013	LAL-31231851B1	42	11,35%	39,46%
01/01/2013	NBEBP-TRIP-3123101B	42	11,35%	50,81%
01/01/2013	STBP-3123101B	42	11,35%	62,16%
01/01/2013	PAL-31231496	33	8,92%	71,08%
01/01/2013	LAH-31231304A	13	3,51%	74,59%
01/01/2013	PAH-31231486	7	1,89%	76,49%
01/01/2013	LAH-31231302B	6	1,62%	78,11%
01/01/2013	TAH-31231306	6	1,62%	79,73%
01/01/2013	PAH-31231488	4	1,08%	80,81%
01/01/2013	PAH-31231489	4	1,08%	81,89%
01/01/2013	PAHH-31231488	4	1,08%	82,97%
01/01/2013	PAHH-31231489	4	1,08%	84,05%
01/01/2013	LAH-31231304B	4	1,08%	85,14%
01/01/2013	LAH-31231310A	4	1,08%	86,22%
01/01/2013	LAH-31231310B	4	1,08%	87,30%
01/01/2013	LAHH-31231304B	4	1,08%	88,38%
01/01/2013	TAH-31231211	4	1,08%	89,46%
01/01/2013	PAL-31231488	3	0,81%	90,27%
01/01/2013	PAL-31231489	3	0,81%	91,08%
01/01/2013	PAL-31231486	3	0,81%	91,89%
01/01/2013	PAL-31231871A	3	0,81%	92,70%
01/01/2013	XA-31231511A	2	0,54%	93,24%
01/01/2013	XA-31231511B	2	0,54%	93,78%
01/01/2013	XA-31231511C	2	0,54%	94,32%
01/01/2013	XA-31231511D	2	0,54%	94,86%
01/01/2013	XA-31231511E	2	0,54%	95,41%
01/01/2013	XA-31231511F	2	0,54%	95,95%
01/01/2013	AAH-31231004	2	0,54%	96,49%
01/01/2013	LAX-31231302B	2	0,54%	97,03%
01/01/2013	PAL-31231258	2	0,54%	97,57%
01/01/2013	TAL-31231010	2	0,54%	98,11%
01/01/2013	PALL-31231488	1	0,27%	98,38%
01/01/2013	PAL-31231252A	1	0,27%	98,65%
01/01/2013	PAL-31231252B	1	0,27%	98,92%
01/01/2013	PAL-31231265	1	0,27%	99,19%
01/01/2013	TAH-31231055	1	0,27%	99,46%
01/01/2013	TAH-31231258	1	0,27%	99,73%
01/01/2013	TAH-31231266	1	0,27%	100%
Total	39	370	100%	-

A Figura 19, obtida com auxílio do *software Microsoft Excel®*, ilustra o resultado gráfico obtido com este tipo de análise. As colunas indicam o número de ativações de cada *tag* de alarme, enquanto a linha representa a frequência acumulada dos alarmes. Observa-se que a *tag* PAL-31231818 sozinha é responsável por 28,11% do total de ativações de alarmes ocorridos no dia 01/01/2013 e que as seis primeiras *tags* juntas são responsáveis por 74,59% do número de ocorrências na planta. Nota-se que a forma gráfica é mais intuitiva do que a forma de tabela. Para facilitar a legibilidade do gráfico, em dias onde o número de ocorrências é demasiadamente grande, pode-se optar por ilustrar apenas as 20 *tags* de alarmes mais atuantes na unidade.

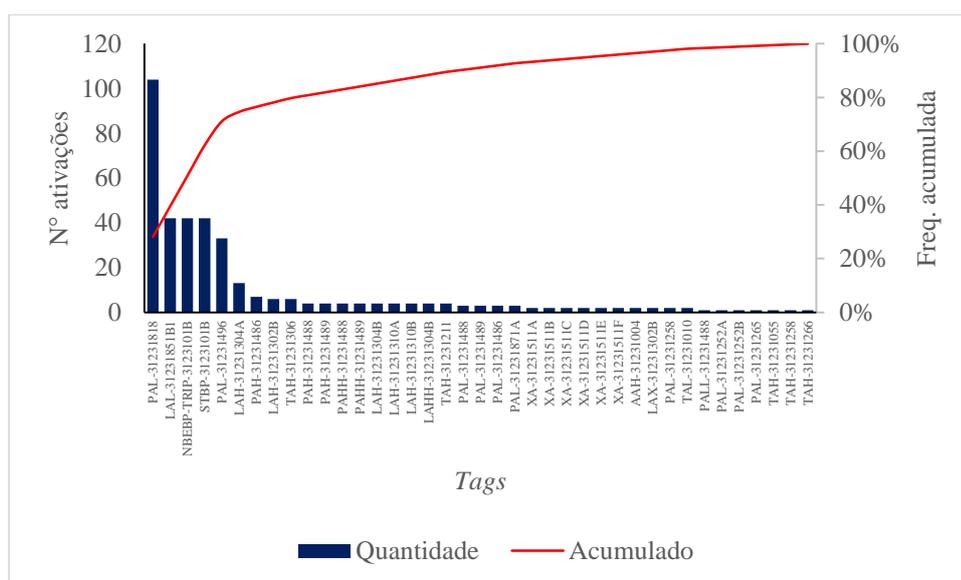


Figura 19. Resultado obtido com a análise de Pareto.

- Análise de ocorrência

A Tabela 8 resume, utilizando dados reais da planta, a estrutura básica necessária para a realização da análise de ocorrência. Nota-se a existência de 4 diferentes *tags* de alarmes, embora a *tag2*, *tag3* e *tag4* apresentem mesmo comportamento dinâmico ao longo do período de amostragem. O intervalo de amostragem considerado foi de 11 segundos, ou seja, dentro de um intervalo de 24 horas a cada 11 segundos os estados dos alarmes foram avaliados. Alarme ativado é representado pelo número 1, enquanto alarme não ativado é representado pelo número 0.

Tabela 8. Estrutura para a realização da análise de ocorrência.

Tempo	PAL-31231496	LAL-31231851B1	NBEBP-TRIP-3123101B	STBP-3123101B
00:00:00	0	0	0	0
00:00:11	0	1	1	1
00:00:21	0	0	0	0
00:00:31	0	1	1	1
00:00:41	1	0	0	0
00:00:51	0	1	1	1
00:01:01	0	0	0	0
00:01:11	1	1	1	1
00:01:21	1	0	0	0
00:01:31	1	1	1	1
00:01:41	0	0	0	0
00:01:51	0	1	1	1
00:02:01	0	0	0	0

A Figura 20, obtida com auxílio do *software* MATLAB®, mostra o resultado obtido com a análise de ocorrência em um intervalo de tempo de amostragem de 7.000 segundos. Observa-se que a alternância entre os estados de alarme ativado e alarme não ativado das *tags* 1, 2 e 3 é tão frequente que o gráfico praticamente assume uma faixa com cor sólida durante todo o intervalo de tempo observado. Este resultado parece refletir algum tipo de redundância no sistema e, portanto, passível de simplificação.

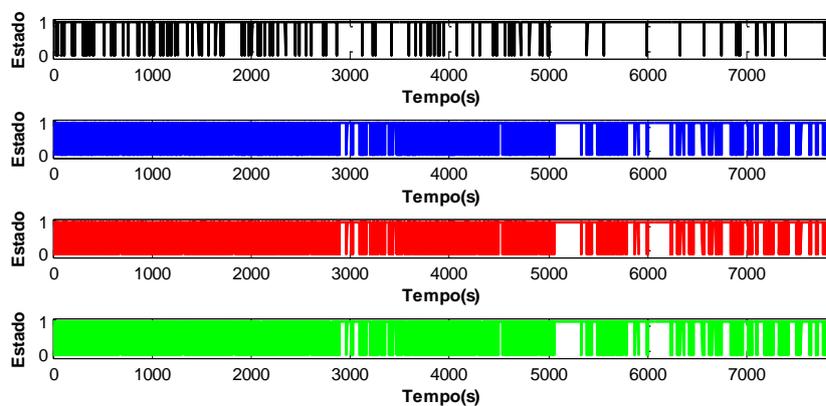


Figura 20. Resultado obtido com análise de ocorrência.

Esta observação a partir do dado do alarme, também pode ser realizada a partir da variável do processo. Neste caso, se a redundância realmente existir, então é esperado que

os alarmes apresentem o mesmo comportamento temporal. O fato de isso não ocorrer pode indicar que existe algum problema no instrumento de medição e/ou divergências nos parâmetros de configuração do sistema de alarmes.

3.2. Apresentação da Unidade

Conforme Máximo Filho (2005), o gás natural, assim como o petróleo, é o resultado do processo de transformação e decomposição anaeróbia de matéria orgânica datadas das eras pré-históricas. Esse processo, ao envolver diferentes condições geológicas, físicas, químicas e biológicas, resultou na formação de reservatórios de hidrocarbonetos por toda a crosta terrestre. O gás natural encontrado na natureza é uma mistura de hidrocarbonetos (tipicamente metano- CH_4 , etano- C_2H_6 , propano- C_3H_8 e butano- C_4H_{10} , com menores quantidades de pentano- C_5H_{12} , hexano- C_6H_{14} , heptano- C_7H_{16} , octano- C_8H_{18} , nonano- C_9H_{20} , decano- $\text{C}_{10}\text{H}_{22}$) e outros componentes que normalmente são considerados contaminantes (principalmente nitrogênio- N_2 , água- H_2O , monóxido de carbono- CO , dióxido de carbônico- CO_2 , ácido sulfídrico- H_2S).

De acordo com Vaz *et al.* (2008), a presença de contaminantes no gás natural traz uma série de problemas. Por exemplo, diminui o poder calorífico, retira o gás da especificação para venda, gera ácidos potentes que ocasionam a corrosão de dutos e equipamentos, além de contribuir para a formação de hidratos nas tubulações. Os hidratos compreendem uma solução sólida, visualmente similar ao gelo, com composição mal definida e constituído por moléculas de hidrocarbonetos de baixo peso molecular e água. A causa fundamental do problema da formação de hidratos é a presença de água livre (fase líquida) ou em equilíbrio com o gás na fase vapor. O problema se torna crônico quando o gás atinge temperaturas mais baixas.

Apesar dos custos e dos problemas ambientais, os combustíveis fósseis ainda representam cerca de 85% da energia primária consumida no mundo. Ou seja, considerando todas as fontes utilizadas no mundo e todos os tipos de energia, o petróleo, o carvão mineral e o gás natural são responsáveis por 85% da energia gerada. Dentro desta porcentagem, 23% é atribuído ao gás natural (VIEIRA *et al.*, 2005). Um estudo realizado pela Empresa de Pesquisas Energéticas (EPE) projetou um investimento em infraestrutura na ordem de R\$ 15 bilhões para o crescimento da oferta de gás natural no Brasil, o que corresponde atualmente a 45% do total consumido no país. Isto significa um salto de produção de 49 milhões de m^3/dia em 2009 para aproximadamente 116 milhões de m^3/dia em 2019 (EPE, 2010). Para Máximo Filho (2005), parte deste crescimento pode

ser atribuído aos benefícios ambientais no uso do gás natural, já que o gás natural é menos poluente: a combustão é mais limpa, dispensa tratamentos dos produtos lançados na atmosfera e dissipa-se facilmente em caso de vazamento. Isto explica o aumento do consumo de gás nos últimos anos, tanto no Brasil quanto mundialmente.

O gás natural não é consumido *in natura*. Antes de ser consumido, o gás natural precisa ser processado. O processamento de gás natural consiste num conjunto de operações unitárias que visa a separar os componentes mais pesados do gás em uma corrente líquida, tornando o gás mais leve. A corrente líquida, normalmente formada pelo propano e mais pesados, é conhecida como Líquido de Gás Natural (LGN), podendo conter também etano. O LGN é fracionado do gás para gerar produtos de maior valor energético e, conseqüentemente, maior valor econômico. Os principais produtos são os seguintes: etano (quando houver etano em sua composição), gás liquefeito de petróleo (GLP), popularmente conhecido como gás de cozinha, e nafta leve. Já o gás mais leve, de menor valor energético, é conhecido como gás processado (ou gás seco) e é formado basicamente por metano, podendo em alguns casos incluir o etano. Este é o gás especificado para o consumo residencial, comercial, veicular e em usinas de geração de energia (termelétricas).

Existem diversos livros-texto que apresentam, em detalhes, as etapas envolvidas no processamento do gás natural. Dentre os quais é possível citar Madoxx e Jhon (1982), Beggs (1984), GPSA (1998), Abdel-Aal *et al.*, (2003), Seider, Seader e Lewin (2003), Lyons e Plisga (2005), Mokhatab *et al.*, (2006) e Kidnay e Parrish (2006). Basicamente, a cadeia produtiva de gás natural compreende um conjunto de atividades sequenciais que funcionam de forma integrada, podendo ser divididas em exploração, condicionamento e processamento. A exploração é a etapa inicial do processo e consiste no reconhecimento e estudo das estruturas propícias ao acúmulo de petróleo ou gás natural, tendo como objetivo a descoberta dos reservatórios. A fase do condicionamento consiste em um tratamento primário do gás produzido, ainda no campo de produção, para que este seja transferido para as unidades de processamento em condições seguras. Na fase do processamento, o gás natural é beneficiado e separado em produtos especificados e adequados para a comercialização.

Uma Unidade de Processamento de Gás Natural (UPGN) é composta basicamente por uma área fria, uma área quente e sistemas auxiliares. A área fria (temperaturas mais baixas e pressões mais altas) é responsável pela liquefação dos componentes pesados do GN, gerando uma fração líquida de alto valor agregado. A área quente (temperaturas mais

altas e pressões mais baixas) é responsável pelo fracionamento do líquido de GN gerado na área fria em produtos finais com especificação bem definida. Os sistemas auxiliares são responsáveis pela geração das facilidades necessárias para a perfeita operação das áreas fria e quente. Normalmente fazem parte deste sistema o sistema de aquecimento de óleo térmico e o sistema de compressão de propano (VAZ *et al.*, 2008).

De acordo com Máximo Filho (2005), os hidrocarbonetos recuperados podem ser estabilizados e separados por fracionamento, para obtenção dos produtos desejados, na própria UPGN ou em outras unidades específicas, tais como as Unidades de Fracionamento de Líquidos (UFL) e Unidades de Processamento de Condensado de Gás Natural (UPCGN).

Existem muitas configurações possíveis para uma Unidade de Processamento de Gás Natural. De acordo com Vaz *et al.* (2008), a escolha do tipo de processo a ser utilizados depende de fatores como a qualidade requerida do gás processado, a curva de produção do reservatório, a vazão de gás natural disponível, os produtos requeridos, a proximidade dos centros consumidores, o tempo de retorno do capital investido, dentre outros. Certamente, a composição do gás natural a ser tratado é um dos itens mais relevantes para a escolha do tipo de processo a ser utilizado. Gases com baixo teor de propano e etano podem ser enquadrados com facilidade, apenas ajustando-se as frações mais pesadas, como butanos e pentanos. Esse ajuste é facilmente conseguido com qualquer um dos processos citados, inclusive o processo Joule-Thompson.

O objetivo principal da unidade foco deste presente estudo de caso é tratar o gás natural bruto, permitindo obter Gás Liquefeito de Petróleo (cortes de C₃ e C₄), Gás Combustível de Venda (cortes de C₁ e C₂) mediante especificação e nafta petroquímica (C₅ e mais pesados, ou C₅+). A unidade foi projetada para condições amplas de qualidade da carga, podendo processar gás de alta riqueza (componentes do gás natural mais pesados que o propano superior a 8%) e gás de baixa riqueza. Para que isso seja possível, a unidade foi dimensionada para o caso de alta riqueza e, para ser capaz de processar o gás de baixa riqueza, ela conta com linhas de recirculação e possibilidades de desvios nos permutadores de calor.

Uma visão geral da planta é apresentada no diagrama de blocos da Figura 21. Em linhas gerais, o gás natural bruto entra na UPGN e segue direto para o sistema de secagem para remoção de vapor d'água. Esta etapa é imprescindível ao processo, pois a presença de baixas temperaturas e metano favorecem a formação de hidratos (mistura sólida formada principalmente por estes dois componentes) que podem obstruir linhas e

equipamentos, causando a parada da planta. O gás também precisa ser seco para atender à especificação de ponto de orvalho estabelecida pela ANP.

Após seco, o gás segue a unidade criogênica que possui este nome em virtude das baixas temperaturas de trabalho. Na etapa do processo o gás é resfriado com o objetivo de promover a condensação das frações de hidrocarbonetos mais pesadas. Após ser resfriado, o gás segue para a seção do turbo-expansor. O objetivo da turbo-expansão (TE) é aproveitar a energia existente no próprio gás natural para economizar energia na etapa de compressão do gás de venda. A redução na pressão do gás obtida na etapa de expansão também é necessária para a separação na torre desmetanizadora.

Na torre desmetanizadora obtêm-se metano (C1) no topo e cortes de etano e mais pesados (C₂+) no fundo. Do topo da torre desmetanizadora sai o gás rico em metano, que volta para a unidade criogênica para trocar calor antes de seguir para o compressor do turbo-expansor. A etapa de compressão é responsável pelo envio do gás de venda para o mercado consumidor via gasoduto de exportação. A corrente de fundo da torre desmetanizadora (C₂+) é bombeada para a torre desmetanizadora.

No topo da torre desmetanizadora sai o etano (C2) e no fundo sai uma corrente com cortes de propano e mais pesados (C₃+). O vapor de etano que sai no topo da torre desmetanizadora é usado como combustível no forno, turbina e motor do compressor. A corrente de fundo da torre desmetanizadora escoar para a torre desbutanizadora. O GLP, produto de topo da torre desbutanizadora, segue para estocagem em esferas pressurizadas. Já a corrente de fundo da torre desbutanizadora, formada por cortes de pentanos e mais pesados (C₅+) é direcionada para a tancagem.

Diversos problemas podem ocorrer em uma UPGN, como, formação de hidrato, parada dos compressores de propano, arraste de líquido na absorção, perda de nível no fracionamento, falhas diversas no sistema de óleo térmico, falha do sistema supervisor de controle, parada do turbo-expansor, entre outras (VAZ *et al.*, 2008). Estas falhas, somadas ao fato da unidade poder operar com cargas de gás natural mais ricas ou pobres, acabam desencadeando uma série de ativações de alarmes na planta.

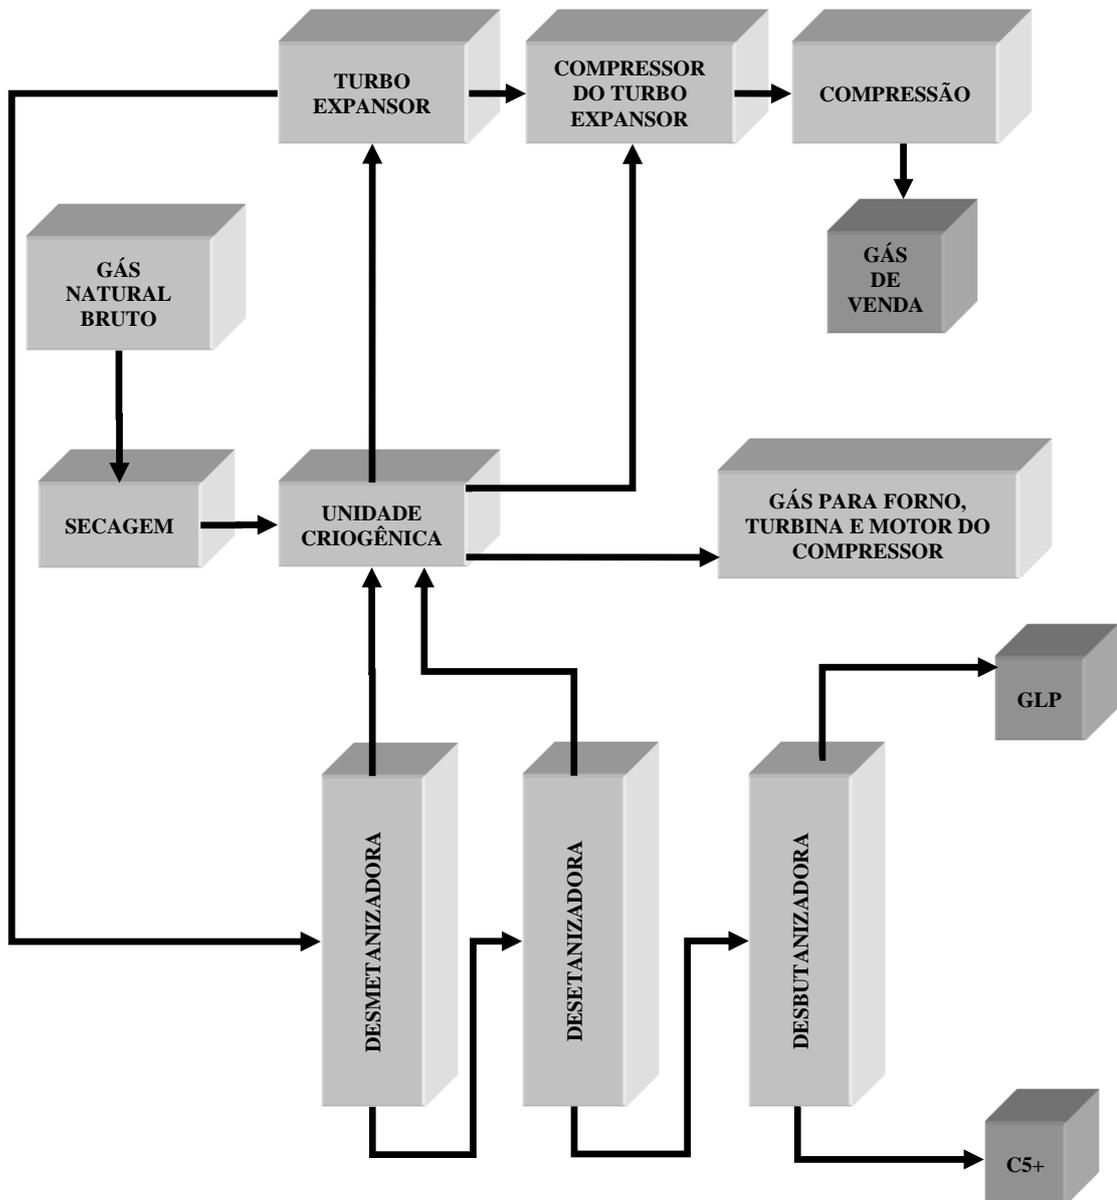


Figura 21. Visão simplificada da planta de processamento de gás natural.

Se por um lado os acidentes precisam ser evitados, por outro lado não existe processo totalmente seguro, de maneira que é impossível eliminar por completo todos os riscos existentes em uma instalação. A alternativa prática é conviver com o risco a um nível tolerável, adotando práticas de mitigação e prevenção. Ao longo dos anos, diversos acidentes ampliados em plantas industriais ocorreram com elevada repercussão negativa, em função da extensão dos danos causados (BAYBUTT, 2002; DZIUBINSKI *et al.*, 2006; BAUM *et al.*, 2009; MURPHY *et al.*, 2009; PCHARA *et al.*, 2010).

De maneira geral, os acidentes em uma planta industrial podem ser analisados sob a ótica da segurança ocupacional ou da segurança de processo. Na primeira abordagem o foco principal é a verificação do cumprimento das boas práticas comportamentais, tais como a utilização dos equipamentos de proteção individual (EPIs), diálogos comportamentais, treinamentos gerais em segurança, saúde, meio ambiente (SSMA), entre outros. O objetivo principal da segurança ocupacional é evitar acidentes como quedas de altura, escorregões, choques elétricos, atropelamentos, queimaduras, cortes *etc*, que resulte em lesões com ou sem afastamento (SOARES, 2010).

Na segunda abordagem, analisam-se os eventos que decorrem do processo produtivo e cujos desdobramentos podem resultar em acidentes de proporções ampliadas. É o caso, por exemplo, do vazamento de substâncias tóxicas, produtos inflamáveis, ocorrência de incêndios, explosões, liberações radioativas, entre outras. Esta classe de acidentes é tratada pela segurança de processos e foco principal é a avaliação dos projetos de engenharia das instalações, análise de perigo e riscos, análise de investigação de acidentes e incidentes, gestão da mudança, gestão de alarmes, procedimentos de partida, parada, operação, treinamento *etc* (SOARES, 2010). Não se discute aqui a importância das duas categorias para a segurança final de uma planta industrial, de maneira que as duas sempre devem existir e, de alguma maneira, se associar. Destaca-se que um bom desempenho em segurança pessoal não assegura um bom desempenho em segurança de processo e vice-versa.

3.3. Análise Inicial do Sistema de Alarmes

A UPGN foco do presente estudo de caso dispõe de uma única sala de controle onde se concentra as principais informações da planta. Para supervisionar e monitorar, em tempo real, as variáveis do processo e os alarmes a unidade conta com o sistema SCADA. Conforme apontado por Maia (2002), o esquema básico de um sistema supervisório é constituído, em princípio, pela inclusão de um microcomputador do tipo PC (*personal computer*) a um sistema de controle já implementado, que na maioria dos casos é formado por um PLC (*programmable logic controller*) e seus periféricos. Em Campos e Teixeira (2006) são apresentadas algumas implementações típicas de estratégias de controle em sistemas supervisórios industriais.

De acordo com Paiola, (2011), há alguns anos todos diriam que a função do sistema supervisório era permitir a visualização e a operação de um processo de maneira remota, através de uma interface-homem-máquina (IHM). Certamente, essa continua

sendo a função primordial do SCADA mas, definitivamente, não é a única. O uso do supervisor abriu um universo de possibilidades, sendo muitas vezes utilizado como fonte de informação para bancos de dados específicos (os historiadores industriais), com capacidade de armazenamento e consultas baseadas no tempo, que fazem parte das soluções PIMS (*plant information management system*).

O SCADA utilizado na unidade oferece ao operador da sala de controle a capacidade de confeccionar gráficos e apontar tendências. Desta forma, o operador tem à sua disposição uma tela gráfica representando parte do processo, ou o processo como um todo, seus parâmetros e os valores reais de campo. As telas gráficas ilustram o processo com seus parâmetros e variáveis e contêm, também, alguns elementos lógicos como botões de liga/desliga, potenciômetros deslizantes, caixas de valores de *setpoints* de alarmes, parâmetros de controle, entre outras funções. Através dele, é possível, por exemplo, verificar se um equipamento está ligado ou desligado, a porcentagem de abertura de uma válvula, o estado de um alarme (ativado ou não ativado), entre outras informações relevantes à operação da planta.

Consultando o banco de dados do SCADA foram identificados 13.903 diferentes *tags* de alarmes digitais configurados na planta. Desse montante, 4.932 (35,47%) são utilizados para monitorar a pressão, 3.491 (25,11%) o nível, 3.373 (24,26%) a temperatura, 1.340 (9,64%) a vazão, 420 (3,02%) o diferencial de pressão, 304 (2,19%) a concentração e 43 (0,31%) a vibração, conforme pode ser visto na Tabela 9. A distribuição dos alarmes na unidade pode sugerir a ordem de maior preocupação com o monitoramento das variáveis do processo.

Tabela 9. Distribuição dos alarmes digitais configurados na planta.

Instrumento	Pontos de alarmes	Porcentagem
PIT	4.932	35,47%
LIT	3.491	25,11%
TIT	3.373	24,26%
FIT	1.340	9,64%
PDIT	420	3,02%
AIT	304	2,19%
VIT	43	0,31%
Total	13.903	100%

A distribuição do nível de prioridade desses alarmes segue apresentada na Tabela 10. Observa-se grande discrepância entre os valores sugeridos pela norma ISA (2009) e os valores presentes na planta, o que sugere um importante ponto de melhoria. Parte desta discrepância pode ser atribuída à falta de conhecimento sobre as boas práticas em gerenciamento de alarmes e a aparente falta de uma metodologia capaz de auxiliar o processo de priorização. Destaca-se ainda que não foi identificado nenhum critério formal capaz de justificar a classificação de prioridade dos alarmes utilizada na planta.

Tabela 10. Diferenças entre os níveis de prioridade dos alarmes da planta.

Prioridade	Referências	Planta
Crítico	< 1%	3%
Alta	5%	37%
Média	15%	26%
Baixa	80%	34%

3.4. Resultados Obtidos com a Implementação da Metodologia

Durante o período compreendido entre os dias 01/01/2013 (primeiro dia de aplicação da metodologia proposta neste trabalho) a 31/12/2015 (último dia de aplicação da metodologia proposta neste trabalho) foram coletados diariamente todas as ocorrências de alarmes registradas na planta e arquivadas no sistema SCADA. Ao todo foram 1.847.346 ocorrências de alarmes digitais, distribuídos ao longo dos meses conforme apresentado na Tabela 11. Nota-se uma elevada taxa de ativação de alarmes durante todos os meses analisados, o que sugere importante oportunidade de melhoria. Além disso, não foi identificado na planta nenhuma prática de gerenciamento de alarmes implantada. Esta ausência de metodologia para identificar pontos de melhorias resultou no desenvolvimento do protocolo de gerenciamento de alarmes apresentado na seção 3.1 deste capítulo.

Normalmente, a falta de uma metodologia formal em gerenciamento de alarmes na etapa de projeto faz com que diversos pontos de alarmes sejam incluídos nas plantas industriais sem uma análise crítica mais apurada. Prefere-se pecar pelo excesso do que pela falta de monitoramento. Esta forma de raciocínio, no entanto, traz sérios riscos, pois sobrecarrega os operadores com um número de ocorrências de alarmes acima da sua capacidade de diagnóstico e compreensão dos eventos ocorridos no processo.

Tabela 11. Distribuição das ocorrências de alarmes na planta.

Mês	2013	2014	2015
Jan	102.917	91.298	33.023
Fev	81.829	49.989	32.493
Mar	77.574	45.170	33.756
Abr	101.349	57.450	40.224
Mai	78.127	45.608	41.552
Jun	96.205	34.959	38.669
Jul	56.491	56.077	41.965
Ago	56.856	58.199	42.290
Set	43.676	47.427	39.000
Out	42.319	35.264	24.314
Nov	39.006	33.805	26.193
Dez	65.584	30.189	26.499
Total	841.933	585.435	419.978

De maneira geral, os problemas identificados na planta puderam ser classificados em três grupos distintos com ações de melhorias comuns, conforme apresentado a seguir:

- Grupo I: parâmetros mal configurados

Busca-se adequar os parâmetros de configuração do sistema de alarmes, tais como valores de *setpoint*, *deadband*, *delay time*, *scan time etc.* Estas ações, embora em alguns casos resulte em maior complexidade, são de rápida implementação e permitem um ganho significativo na redução da taxa de ativação de alarmes na unidade. No entanto, deve-se esclarecer que elas não resolvem as causa(s) do(s) problema(s), servindo apenas como um paliativo.

- Grupo II

Buscam-se alterações nos procedimentos operacionais, como solicitar aos operadores que mantenham o nível de um vaso fora da região do *setpoint* do alarme. Esta mudança de atitude muitas vezes atua na causa do alarme, embora obviamente esteja diretamente relacionada com a confiabilidade que os operadores têm na gestão de alarmes que está sendo realizada.

- Grupo III

Buscam-se modificações físicas na planta, com a substituição/exclusão/inclusão de equipamentos de processo, instrumentos de medição *etc.* Este tipo de atuação também costuma resolver a(s) causa(s) da ativação do alarme, porém são mais demoradas e envolvem custos mais elevados do que as outras duas.

A Figura 22, obtida com auxílio do *software* STATISTIA 6.0®, mostra a distribuição das ocorrências de alarmes digitais na planta, por mês, durante os 3 anos investigados. O primeiro resultado obtido com as práticas de gerenciamento de alarmes propostas neste trabalho foi em fevereiro de 2013. Verifica-se que desde então houve uma redução gradativa e contínua das ocorrências de alarmes ao longo dos meses. Observa-se que no ano de 2015 as ocorrências de alarmes foram muito menores do que 2014 e mais ainda do que 2015, mostrando que o protocolo de gerenciamento de alarmes proposto neste trabalho foi capaz de reduzir as ocorrências de alarmes na planta.

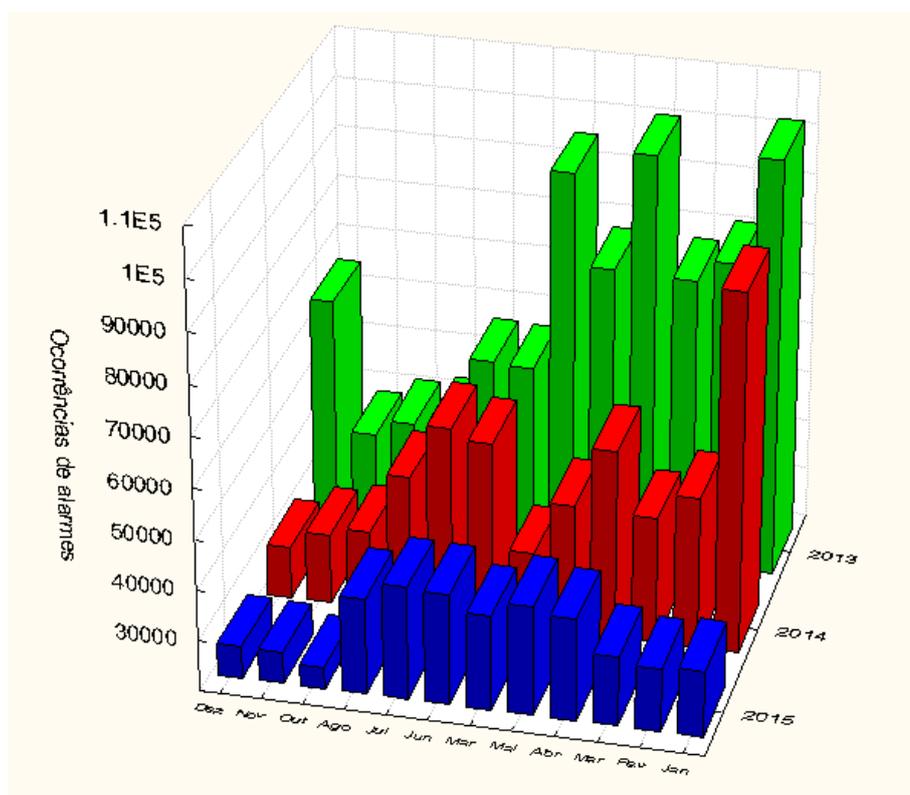


Figura 22. Distribuição das ocorrências de alarmes digitais na planta durante todo o período analisado.

De maneira pragmática, grande parte das ativações de alarmes ocorridas na unidade estavam associadas à configuração ruim dos parâmetros do sistema de alarmes. Muitos alarmes ainda estavam com os valores de *setpoint* baseados nas condições de projeto, condições estas diferentes das condições de operação atual. A elevada taxa de ocorrência de alarmes na planta sugere que as ativações não refletem eventos determinísticos ocorridos no processo. Para investigar esta hipótese, a Tabela 12 mostra os valores percentuais das ocorrências de alarmes na planta em cada mês analisado, tomando-se como referência o número total de ocorrências registradas em cada ano. Portanto, o valor de 12,22% informado na tabela no mês de janeiro do ano de 2013, representa a divisão do valor 102.917 por 841.933 da Tabela 11, e assim sucessivamente.

Tabela 12. Frequência das ocorrências mensais dos alarmes em um ano.

Mês	2013	2014	2015
Jan	12,22%	15,59%	7,86%
Fev	9,72%	8,54%	7,74%
Mar	9,21%	7,72%	8,04%
Abr	12,04%	9,81%	9,58%
Mai	9,28%	7,79%	9,89%
Jun	11,43%	5,97%	9,21%
Jul	6,71%	9,58%	9,99%
Ago	6,75%	9,94%	10,07%
Set	5,19%	8,10%	9,29%
Out	5,03%	6,02%	5,79%
Nov	4,63%	5,77%	6,24%
Dez	7,79%	5,16%	6,31%

* Referência é igual a $1/12 = 8,33\%$.

Na média, pode-se dizer que o valor de referência para a percentual de ativação de um alarme na planta, da maneira como foi calculada é de 8,33%, que representa a relação 1/12, ou seja, 1 mês em 12 possíveis. A Figura 23, obtida com auxílio do software STATISTICA 6.0®, ilustra os percentuais calculadas ao longo dos meses. Observa-se que a frequência de ativação no ano de 2015 se manteve mais uniforme, aproximando-se

do valor de referência. Isto mostra os benefícios conseguidos com a implementação do protocolo de gerenciamento de alarmes apresentado neste trabalho.

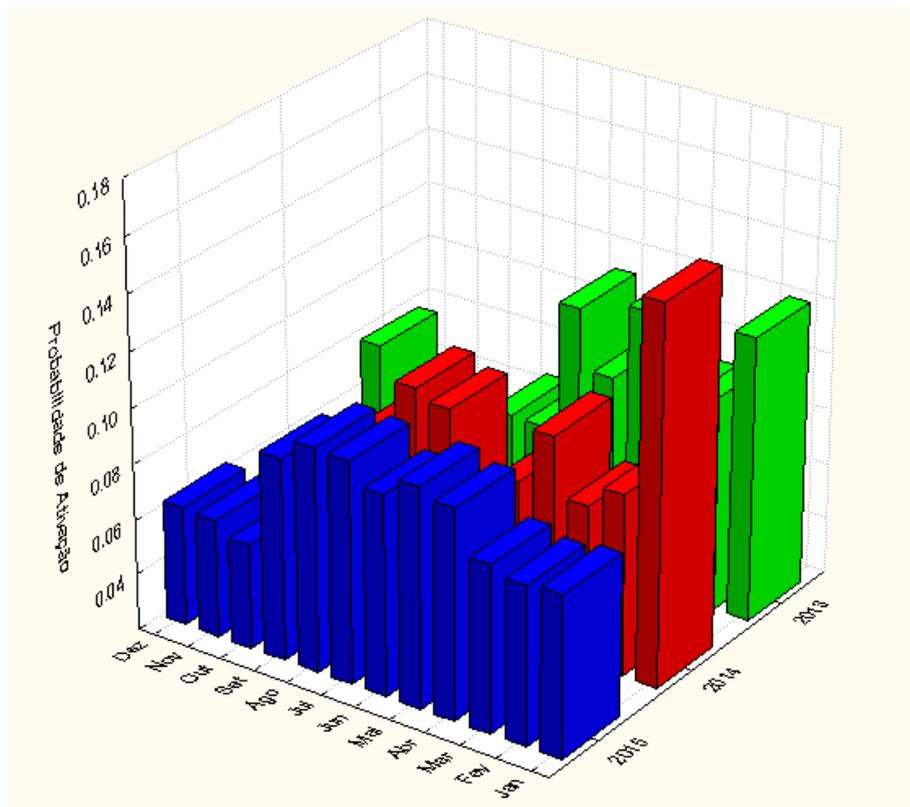


Figura 23. Frequência de ativação com base nas ocorrências mensais em um ano.

Outra maneira utilizada para calcular a frequência de ativação de um alarme na planta foi fazendo a relação do número de ativações registradas em um mês pelo número total de anos analisado. A Tabela 13 mostra os valores percentuais das ocorrências de alarmes na planta em cada mês analisado e, neste caso, o somatório das linhas obrigatoriamente deve ser igual a 100%. O valor de referência para a frequência de ativação de um alarme na planta, da maneira como foi calculada, seria de 33,33%, representando a relação 1/3 (1 mês em 3 possíveis).

A Figura 24, obtida com auxílio do *software* STATISTICA 6.0®, ilustra o comportamento da frequência de ativação dos alarmes ao longo dos meses analisados. Observa-se que a frequência de ativação permaneceu abaixo do valor de referência no ano de 2015, comprovando novamente a eficácia do protocolo de gerenciamento de alarmes desenvolvido neste trabalho.

Tabela 13. Frequência das ocorrências dos alarmes em um mesmo mês em três anos de análises contínuas.

Mês	2013	2014	2015
Jan	45,29%	40,18%	14,53%
Fev	49,80%	30,42%	19,78%
Mar	49,57%	28,86%	21,57%
Abr	50,92%	28,87%	20,21%
Mai	47,27%	27,59%	25,14%
Jun	56,65%	20,58%	22,77%
Jul	36,56%	36,29%	27,16%
Ago	36,13%	36,99%	26,88%
Set	33,57%	36,45%	29,98%
Out	41,53%	34,61%	23,86%
Nov	39,40%	34,15%	26,46%
Dez	53,64%	24,69%	21,67%

* Referência é igual a $1/3 = 33,33\%$.

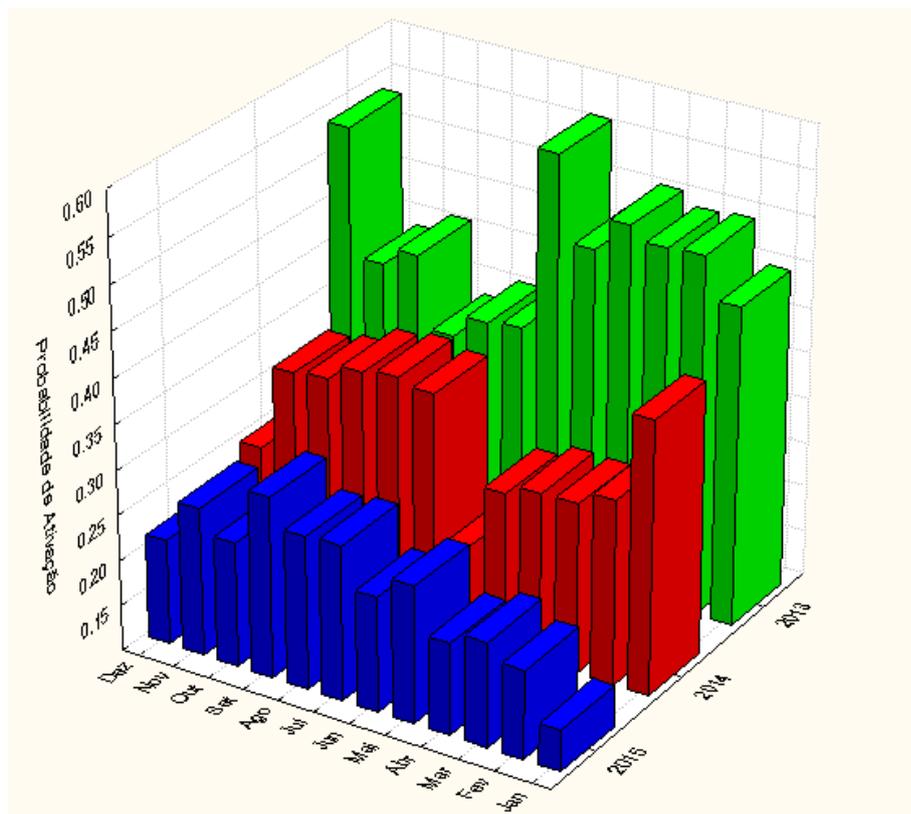


Figura 24. Frequência de ativação em um certo mês ao longo de três anos.

A Tabela 14 apresenta a frequência esperada de alguns eventos de falha que podem ocorrer em uma planta industrial. Por exemplo, é esperado ocorrer 1 evento de falha da malha de controle do SCADA a cada 10 anos, portanto, uma frequência esperada de 0,1 evento/ano. Observa-se que os valores de frequência informados nesta tabela são muito menores do que os valores de frequência informados nas Tabelas 12 e 13. Em outras palavras, a frequência de ativação do alarme por evento de falha no processo é muito pequena. Isto sugere que as ocorrências dos alarmes na planta, muito provavelmente, não estão associadas à eventos determinísticos ocorridos na planta.

Tabela 14. Probabilidade de causas iniciadoras de eventos determinísticos (Adaptado de CONTEC, 2012).

Causa iniciadora	Evento/ano
Falha de malha de controle do SCADA	1×10^{-1}
Falha de equipamento estático (baixa vibração)	1×10^{-2}
Falha de equipamento estático (alta vibração)	1×10^{-1}
Falha de equipamento dinâmico	1×10^{-1}
Falha de vaso de pressão	1×10^{-6}
Ruptura de tubulação	1×10^{-7}
Vazamento em tubulação	1×10^{-5}
Abertura espúria de válvula de segurança	1×10^{-2}
Descarga elétrica atmosférica	1×10^{-3}
Incêndio de pequenas proporções	1×10^{-1}
Incêndio de grandes proporções	1×10^{-2}
Falha do operador em executar procedimento de rotina	1×10^{-2}
Falha geral em procedimento de manutenção	1×10^{-3}
Atuação espúria de SIS	1×10^{-1}

Em função desses resultados, não seria exagero dizer que na planta as ocorrências de alarmes refletem outros eventos não determinísticos, dada à grande quantidade de ativações registradas ao longo dos dias. Com base nas informações apresentadas nas Tabelas 12, 13 e 14, propõe-se o uso da Equação (28) para inferir a probabilidade de ativação do alarme na unidade.

$$P_{\text{ativ.}}(i) = P(F) \cdot P(DF|F) + P_{\text{Aleatório}} \quad (28)$$

Onde: $P_{ativ}(i)$ é a probabilidade de ativação do alarme i na unidade, $P(F)$ é a probabilidade de ocorrer o evento de falha F (Tabela 21) com magnitude $P(DF|F)$ suficiente para atingir o *setpoint* do alarme e $P_{Aleatório}$ é a frequência de ocorrer uma ativação aleatória do alarme. Nota-se que o uso da Equação (28) requer o conhecimento da frequência de ativação do alarme. Neste contexto, o uso de distribuições de probabilidade pode ser apropriado para tentar modelar os resultados de ativações de alarmes observados na planta, justificando o estudo apresentado na próxima secção.

3.5. Análise das Distribuições de Probabilidade dos Alarmes

Conforme apresentado na Equação (9), do Capítulo 2 deste trabalho, a função binomial é a distribuição de probabilidades mais utilizada para descrever o comportamento discreto de uma *tag* de alarme. Para construir a curva binomial é necessário conhecer a probabilidade de ativação (p) do alarme. Neste caso, como inferir esta estatística a partir dos dados obtidos da planta? As Tabelas 12 e 13 oferecem uma alternativa para esta questão, apontando os valores 8,33% e 33,33%, respectivamente, como pontos de referência. Com auxílio da função DISTR.BINOM do *Microsoft Excel*® foi construído a curva binomial para os valores de probabilidade de ativação informados nestas tabelas. A Figura 25 apresenta o resultado obtido. Observa-se que para uma probabilidade de ativação igual a 8,33% é provável que uma mesma *tag* de alarme tenha se repetido no processo por até 10 vezes. Ao passo que, para uma probabilidade de ativação igual a 33,33% é provável que uma mesma *tag* de alarme tenha se repetido no processo entre 6 a 21 vezes.

O exercício não tem qualquer valor intrínseco sobre o processo, mas pretende apenas ilustrar o comportamento da curva binomial. A ideia central é identificar qual a probabilidade de uma *tag* de alarme ocorrer mais de uma vez, dado o número total de ativações registradas ao longo dos 36 meses analisados. Deve-se ressaltar que, para a construção da curva binomial a probabilidade de ativação do alarme (8,33% e 33,33%), assim como o número de tentativas (36 meses), foram considerados constantes. Apenas o número de ativações (parâmetro n) foi alterado. No entanto, as Tabelas 12 e 13 sugerem que esses parâmetros podem sofrer variações.

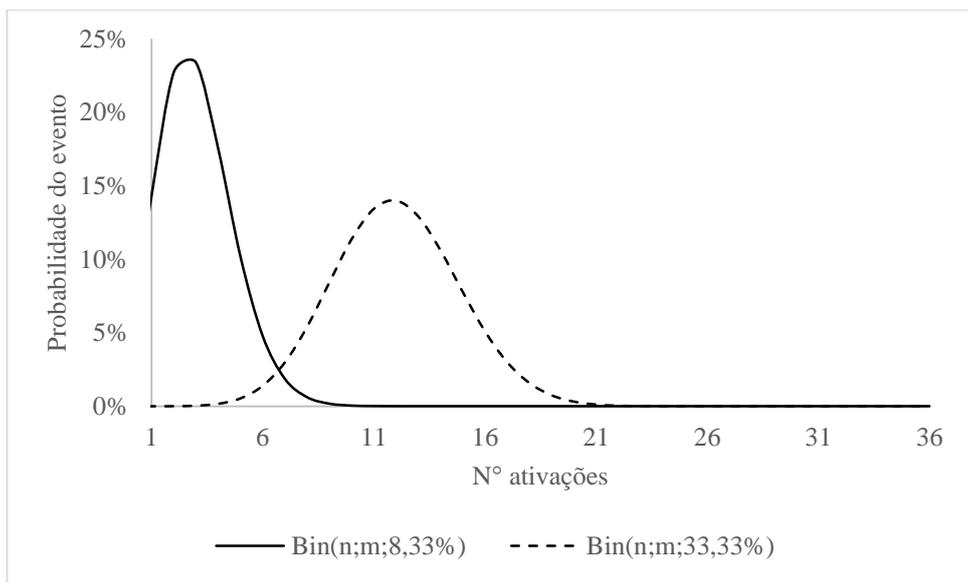


Figura 25. Comportamento da curva binomial para as ativações de alarmes na planta dado o número total de ocorrências registrado no período de três anos.

Conforme já apresentado neste trabalho, a função binomial de probabilidade é utilizada para sistemas com comportamento discretos. No entanto, ao se analisar as ocorrências de alarmes ao longo em um período contínuo de tempo, outras distribuições de probabilidades podem ser utilizadas. O uso dessas distribuições de probabilidades pode ser útil para tentar modelar os resultados de ativações de alarmes observado em uma planta industrial. Neste contexto e, com o auxílio do *software* STATISTICA 6.0®, foram testadas algumas distribuições de probabilidade contínuas para modelar os dados das ativações de alarmes da planta. Os dados utilizados nesta análise estão disponíveis na Tabela 33 do Apêndice 1 deste trabalho.

As Figuras 26, 27, 28 e 29 apresentam o resultado obtido com a aplicação das distribuições normal, exponencial, gama e log-normal, respectivamente. Maiores informações sobre estas distribuições podem ser obtidas em Pinto e Schuwaab (2007), Montgomery (2009) e Mathworks (2010). O eixo x representa as faixas observadas das ocorrências de alarmes nos três anos analisados, enquanto o eixo y indica a frequência observada para cada faixa indicada. Observa-se que a frequência mais observada está entre 1.000 a 2.000 ocorrências de alarmes por dia. Os resultados ainda mostram que nenhuma das funções de probabilidade testadas foram capazes de representar de forma suficientemente boa as ocorrências diárias de alarmes na planta. Isto pode ser percebido pela faixa de ativação de alarmes que não está sob a área da curva da função de probabilidades.

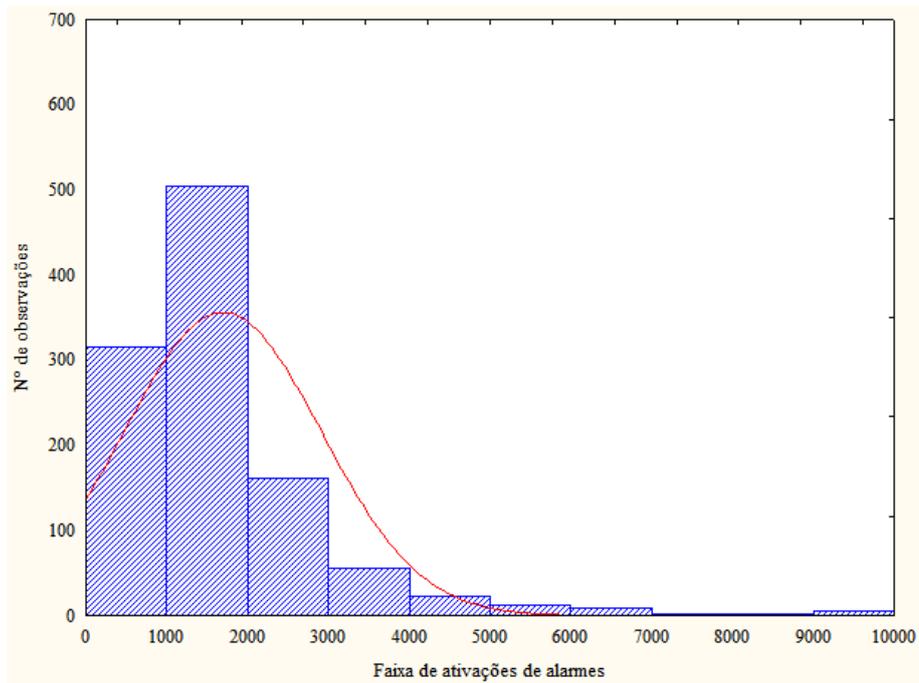


Figura 26. Distribuição normal de probabilidades das ativações mensais dos alarmes em três anos de análise.

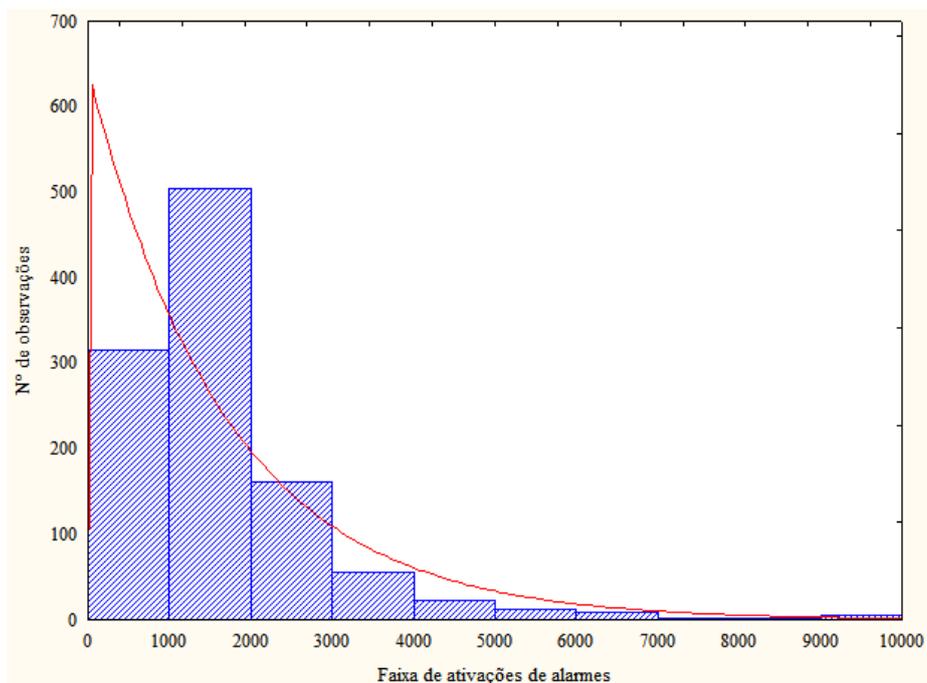


Figura 27. Distribuição exponencial de probabilidades das ativações mensais dos alarmes em três anos de análise.

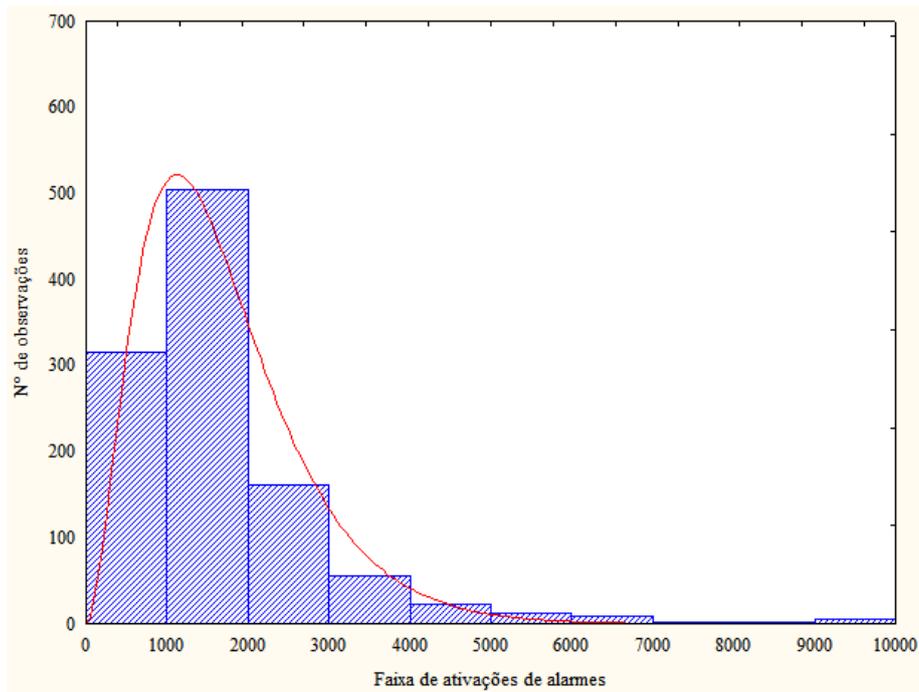


Figura 28. Distribuição gama de probabilidades das ativações mensais dos alarmes em três anos de análise.

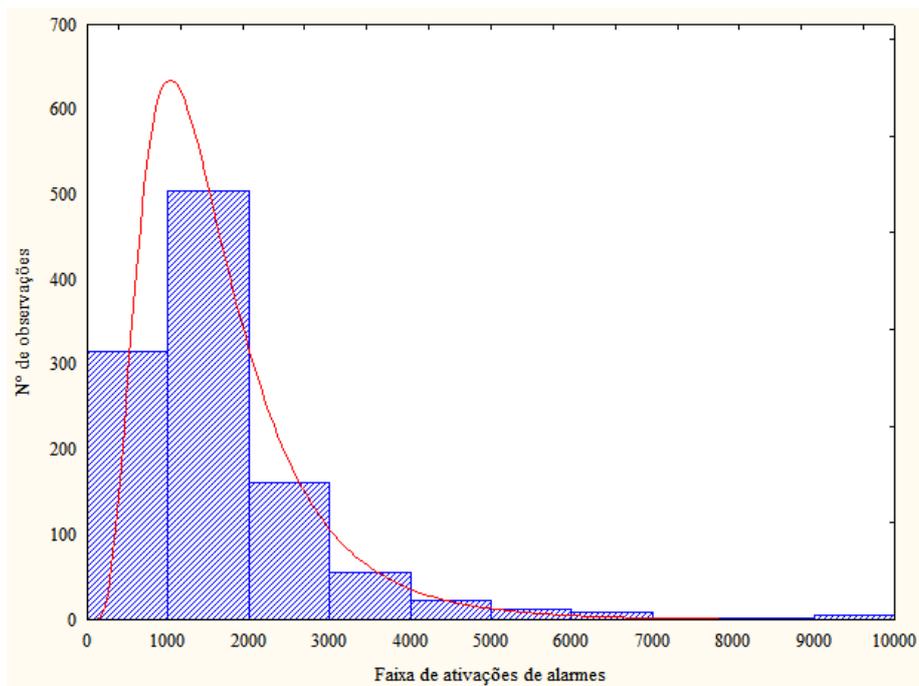


Figura 29. Distribuição log-normal de probabilidades das ativações mensais dos alarmes em três anos de análise.

3.6. Análise de Correlação dos Alarmes e das Variáveis do Processo

A seguir são apresentados dois casos específicos onde o mapa de cores, a análise de agrupamento e a análise de componentes principais foram aplicadas para avaliar a presença de correlações significativas entre as variáveis do processo e, a partir desta constatação, sugerir simplificações no sistema de alarmes.

3.6.1. Caso 1: sistema do forno de óleo térmico

Os dados apresentados na Tabela 15 foram obtidos da planta e representam a primeira tentativa utilizada neste trabalho para avaliar eventuais relações entre *tags* de alarmes diferentes. A métrica consiste em contabilizar todas as ocorrências de alarmes registradas num certo período e, a partir deste resultado, escolher a *tag* de maior número de ocorrências de alarmes como valor referência. Posteriormente, divide-se o número de ativações das demais *tags* pelo valor de referência para determinar a relação entre os sinais de alarmes. Apesar de simples, esta análise de relação não deve ser confundida com a análise de correlação. De fato, não se pode dizer que alarmes com alta relação estão correlacionados, a menos que se comprove alguma relação entre as variáveis do processo para o qual os alarmes foram configurados.

Tabela 15. Proposta para identificação de alarmes relacionados.

<i>Tag</i>	Nº ocorrências	Métrica	Relação
PAH-062	52	52/52	100%
PAH-056	6	6/52	11,54%
LAH-203	3	3/52	5,77%
FAL-801A	2	2/52	3,85%
FAL-801B	2	2/52	3,85%
FAL-801C	2	2/52	3,85%
FAL-801D	2	2/52	3,85%

Outra proposta seria aplicar a Equação (11) apresentada no Capítulo 2 deste trabalho aos estados de alarmes (0-normal; 1-ativado). A Tabela 16 mostra a matriz de correlação obtida com os sinais de alarmes gerados para o mesmo período de tempo da Tabela 22. Durante um período de 1 hora os estados dos alarmes foram amostrados em intervalos fixos de 1 segundo, totalizando 3.600 dados para análise em cada *tag* de alarme. Observa-se que só existe correlação significativa entre as *tags* FAL801A, FAL801B, FAL801C e FAL801D, isto porque, os momentos de ativação desses alarmes foram muito

próximos uns dos outros. Posteriormente será detalhado o sistema onde estes alarmes de vazão baixa estão configurados na planta, relacionando o comportamento das variáveis de processo com os sinais de alarmes através do uso do mapa de cores.

Tabela 16. Matriz de correlação para identificar alarmes correlacionados.

	PAH062	PAH056	LAH203	FAL801A	FAL801B	FAL801C	FAL801D
PAH062	1.00						
PAH056	0.01	1.00					
LAH203	-0.02	-0.08	1.00				
FAL801A	-0.03	-0.01	0.00	1.00			
FAL801B	-0.03	-0.01	0.00	1.00	1.00		
FAL801C	-0.03	-0.01	0.00	1.00	1.00	1.00	
PAH062	-0.03	-0.01	0.00	1.00	1.00	1.00	1.00

Conforme já mencionado neste trabalho, pode-se calcular a auto-correlação que um sinal de alarme apresenta com ele mesmo através da Equação (12). Neste caso, tomou-se a *tag* PAH052 como exemplo. A Tabela 17 mostra o resultado obtido quando os estados de alarmes originais (t_0) são deslocados no tempo em 6 segundos (t_1, t_2, t_3, t_4, t_5 e t_6). É interessante observar que, dinamicamente, os sinais de alarmes não apresentam auto-correlações significativas, o que significa que a distância entre estados de alarmes ativados subsequentes (ou atraso) é grande.

Tabela 17. Matriz de autocorrelação do alarme PAH052.

	t_0	t_1	t_2	t_3	t_4	t_5	t_6
t_0	1.00	-0.17	-0.10	-0.08	-0.03	0.06	-0.03
t_1	-0.17	1.00	-0.17	-0.10	-0.08	-0.03	0.06
t_2	-0.10	-0.17	1.00	-0.17	-0.10	-0.08	-0.03
t_3	-0.08	-0.10	-0.17	1.00	-0.17	-0.10	-0.08
t_4	-0.03	-0.08	-0.10	-0.17	1.00	-0.17	-0.10
t_5	0.06	-0.03	-0.08	-0.10	-0.17	1.00	-0.17
t_6	-0.03	0.06	-0.03	-0.08	-0.10	-0.17	1.00

A ativação de um alarme em uma planta industrial deveria estar associada a algum evento determinístico, de maneira que este sinal de alarme deveria permanecer ativado no processo até que o evento-causa retorne à normalidade. Ou seja, partindo deste pressuposto, é esperado auto-correlação. Portanto, a não observância deste efeito pode indicar alarmes espúrios, oriundos de eventos meramente aleatórios.

Retomando o caso dos alarmes de vazão baixa apresentados na Tabela 22, a Figura 30 ilustra o sistema do forno de óleo térmico ao qual estes alarmes estão associados. Existem, pelo menos, 11 importantes variáveis do processo que são constantemente monitoradas pelos operadores. As *tag1*, *tag2* e *tag3* são utilizadas para monitorar a pressão interna no forno, as *tag4*, *tag5*, *tag6* e *tag7* utilizadas para monitoram a temperatura de saída de cada passe do forno e as *tag8*, *tag9*, *tag10* e *tag11* utilizadas para monitorar as vazões de óleo térmico em cada passe.

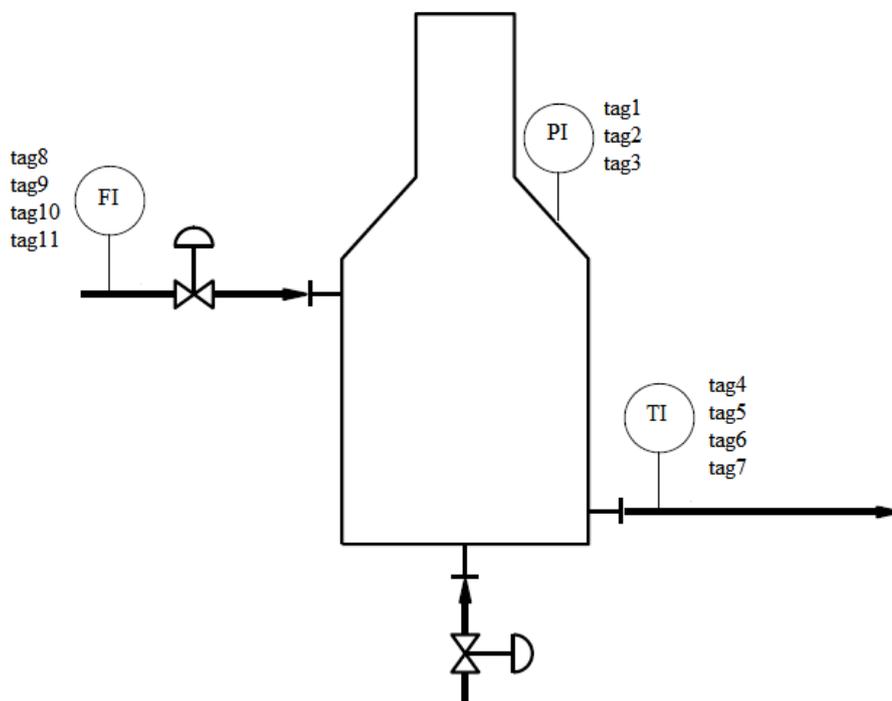


Figura 30. Simplificação do sistema do forno de óleo térmico com indicação das variáveis de processo utilizadas para monitoramento operacional.

Para cada variável do processo apresentada existe uma *tag*s de alarme associada com *setpoint* definido. A Tabela 18 os alarmes de alta (HI) e de baixa (LO), bem como os respectivos valores de *setpoint* configurados na planta.

Tabela 18. Valores originais dos *setpoints* de alarmes configurados no sistema do forno de óleo térmico.

<i>Tag</i>	HI	LO	Unidades
1	- 1,3	-	mmH ₂ O
2	- 1,3	-	mmH ₂ O
3	- 1,3	-	mmH ₂ O
4	255	-	°C
5	255	-	°C
6	255	-	°C
7	255	-	°C
8	-	49,6	m ³ /h
9	-	49,6	m ³ /h
10	-	49,6	m ³ /h
11	-	49,6	m ³ /h

As Figuras 31, 32 e 33 mostram o comportamento temporal das onze variáveis apresentadas. Observa-se que existe comportamento similar entre as pressões, entre as temperaturas e entre as vazões. Este comportamento é particularmente interessante sob o ponto de vista da análise de correlação das *tags* de alarmes.

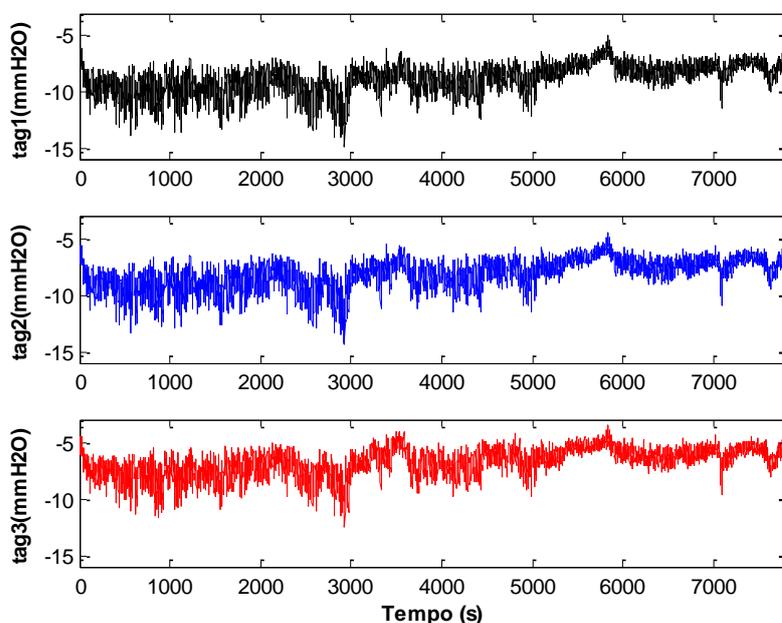


Figura 31. Comportamento das pressões na seção de óleo térmico.

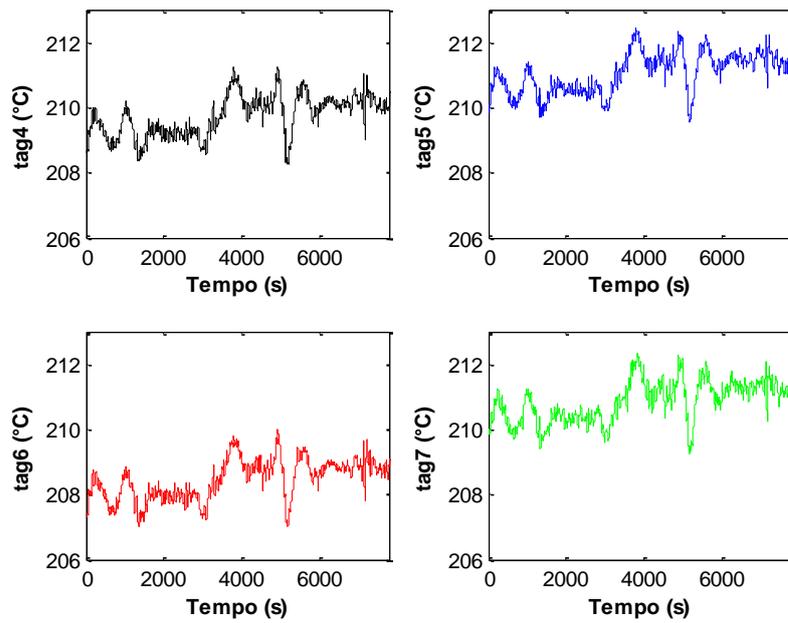


Figura 32. Comportamento das temperaturas na seção de óleo térmico.

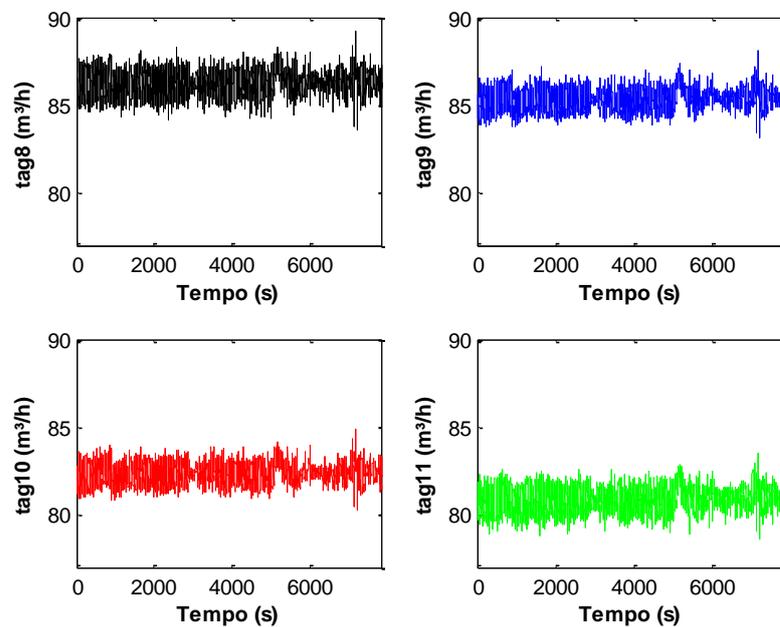


Figura 33. Comportamento das vazões na seção de óleo térmico.

A Tabela 19 apresenta o resumo estatístico (média, desvio-padrão valores máximo e mínimo, respectivamente) do comportamento das variáveis de processo do sistema do forno de óleo térmico para uma condição real de operação.

Tabela 19. Resumo estatístico do comportamento das variáveis do processo do sistema do forno de óleo térmico.

<i>Tag</i>	Média	Desvio-Padrão	Mínimo	Máximo
1	-8,85	1,30	-14,97	-5,01
2	-8,18	1,31	-14,32	-4,53
3	-6,79	1,21	-12,49	-3,57
4	209,73	0,62	208,24	211,22
5	211,06	0,61	209,55	212,42
6	208,46	0,61	207,01	209,98
7	210,85	0,62	209,25	212,32
8	86,21	0,64	83,63	89,23
9	85,28	0,57	83,16	88,10
10	82,31	0,56	80,31	84,92
11	80,84	0,61	78,62	83,53

Ao comparar os valores apresentados nesta tabela com os valores apresentados na Tabela 18 verifica-se que nenhuma variável do processo atingiu o valor do *setpoint* do alarme, portanto, não houve registro de ocorrências de alarmes na planta para o período analisado. A consequência imediata deste efeito é que todos os estados dos alarmes serão 0 de maneira que o uso da Equação (11) é impraticável.

Para permitir o cálculo dos coeficientes de correlação mesmo em situações onde não há registro de ativações de alarmes, assumiu-se o primeiro estado de amostragem dos alarmes como sendo ativado (1). Feito esta consideração as Figuras 34 e 35 ilustram o mapa de cores dos coeficientes de correlação das variáveis do processo e dos alarmes, respectivamente. Observa-se na Figura 34 a presença de 3 regiões com presença de correlações elevadas e positivas. Estas regiões são marcadas pelas pressões, temperaturas e vazões. No entanto, o mesmo comportamento não foi identificado no mapa de cores dos alarmes. Reitera-se que a elevada correlação positiva apresentada no mapa de cores dos alarmes refletem a ausência de dados de estados ativados associado com o uso da estratégia apresentada anteriormente para permitir o cômputo dos coeficientes de correlação.

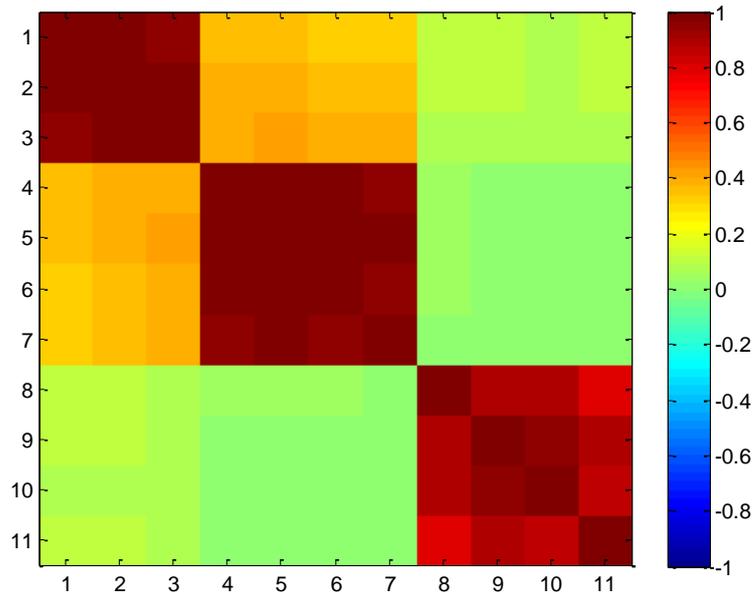


Figura 34. Mapa de cores das variáveis do processo do sistema do forno de óleo.

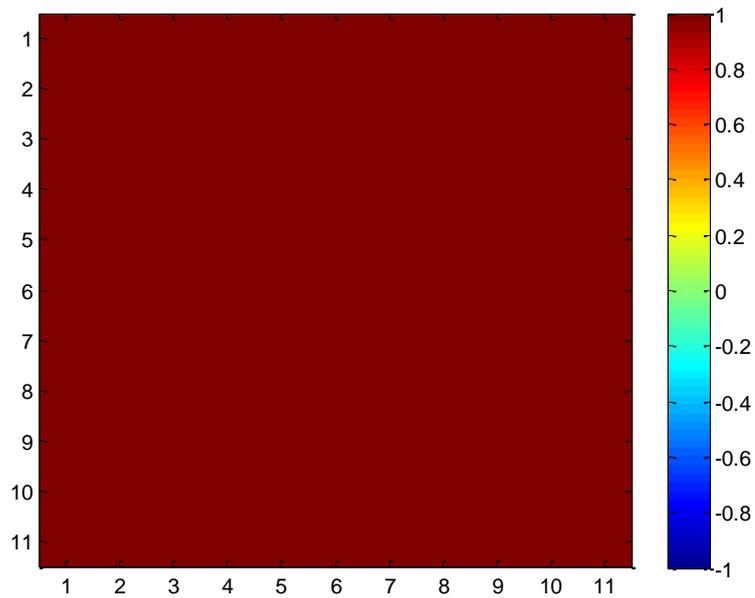


Figura 35. Mapa de cores dos alarmes do sistema do forno de óleo térmico com valores de *setpoint* originais.

A diferença entre os dois mapas de cores permite questionar o quão parecidos estes resultados deveriam. Levando-se em consideração que o processo estava sobre controle, portanto, sem presença de desvios de operação ou falhas, estes mapas deveriam

ser diferentes. Em tese, se não há eventos determinísticos, então não deveria haver ocorrências de alarmes. Por outro lado, se os valores dos *setpoints* de alarmes forem considerados muito expansivos, pode-se utilizar as informações da Tabela 18 como ponto de partida para a configuração dos novos valores dos *setpoints* de alarmes.

A Figura 36 apresenta o comportamento do mapa de cores dos alarmes quando os valores de *setpoint* são alterados para os valores das médias das variáveis do processo. Nota-se que as correlações entre os sinais de alarmes mudam conforme os valores de *setpoint* são alterados e que, o resultado final se aproxima daquele mostrado na Figura 34. O fato dos valores de *setpoint* influenciarem as correlações entre os sinais sugere que estes valores podem ser alterados até que se consiga visualizar mapa de cores semelhantes entre variáveis do processo e sinais de alarmes. Destaca-se também que, a presença de *deadband*, *delay times* e *filtering* também podem resultar em mapas de cores diferentes.

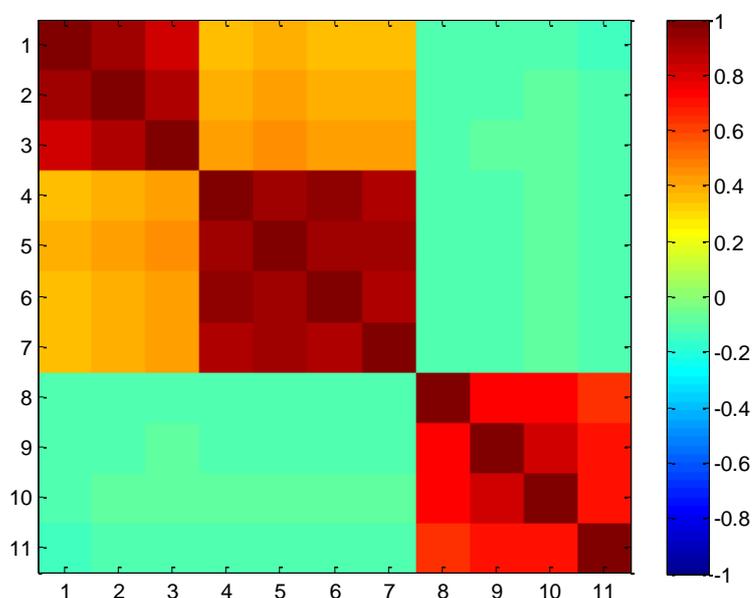


Figura 36. Mapa de cores dos alarmes do sistema do forno de óleo térmico para valores de *setpoint* definidos com base na estatística descritiva.

Conforme já mencionado neste trabalho o coeficiente de correlação calculado a partir da Equação (11) só é aplicável de forma bivariada. Portanto, para grandes conjuntos de dados (não foi o caso do sistema do forno de óleo térmico) avaliar dados de dois a dois podem não ser a estratégia mais conveniente. O uso da Equação (11) também supõe que os dados analisados seguem a distribuição normal de probabilidades, no entanto, já foi

demonstrado neste trabalho que os dados de alarmes não necessariamente seguem este tipo de distribuição.

A Figura 37, elaborada com auxílio do *software* MATLAB®, mostra o resultado obtido para as variáveis do processo normalizadas com o uso da Equação (5). As curvas normais para cada conjunto de dados estão indicadas em vermelho. Como esperado, verifica-se que em sistemas reais os dados não apresentam necessariamente distribuição Gaussiana, o que pode constituir uma limitação para a aplicação de técnicas que admitem necessariamente este tipo de comportamento.

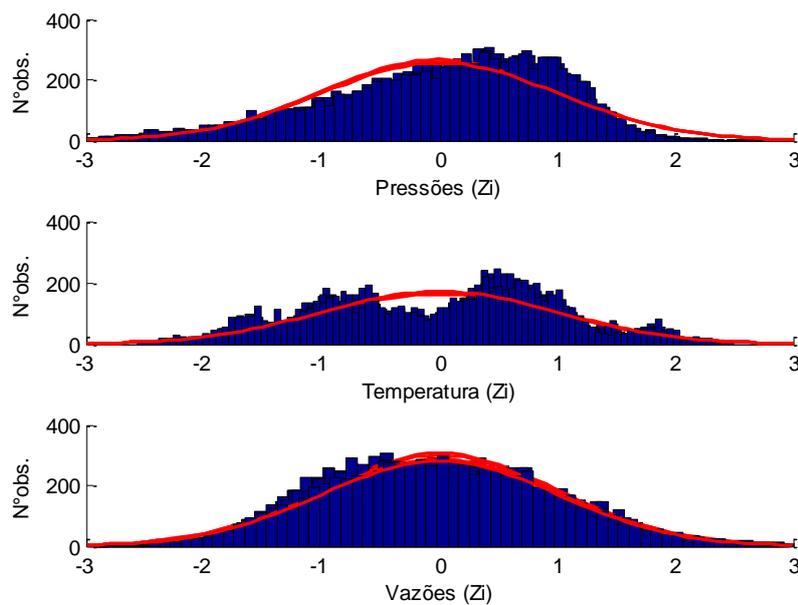


Figura 37. Distribuições das variáveis do processo padronizadas e ajuste normal.

Uma alternativa para contornar as limitações associadas à Equação (11) seria a utilização da análise de agrupamentos. As Figuras 38 e 39, elaboradas com auxílio do *software* MATLAB®, apresentam os dendogramas obtidos quando se utilizava a métrica da distância Euclidiana (não requer conhecimento estático para sua aplicação) e a métrica da Correlação Inversa (requer conhecimento estático para sua aplicação), respectivamente. Em ambos os casos, utilizou-se o método do vizinho mais próximo (*single linkage*) para realizar o agrupamento dos dados. Nas duas figuras o eixo horizontal representa as *tags* das variáveis de processo. As ligações entre estes objetos são representadas por linhas “de cabeça para baixo” e a altura da linha indica a distância entre estes objetos.

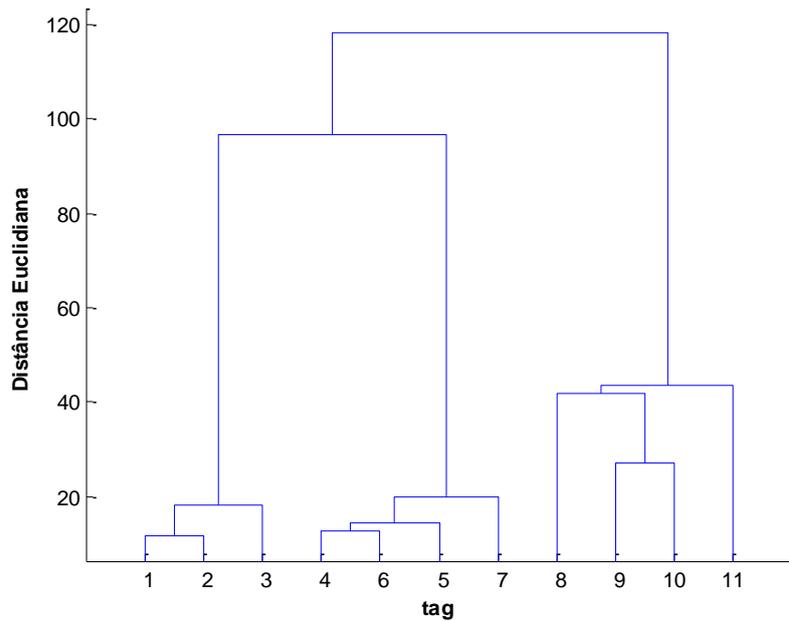


Figura 38. Dendrograma obtido a partir das variáveis do processo da seção de óleo térmico utilizando a distância Euclidiana.

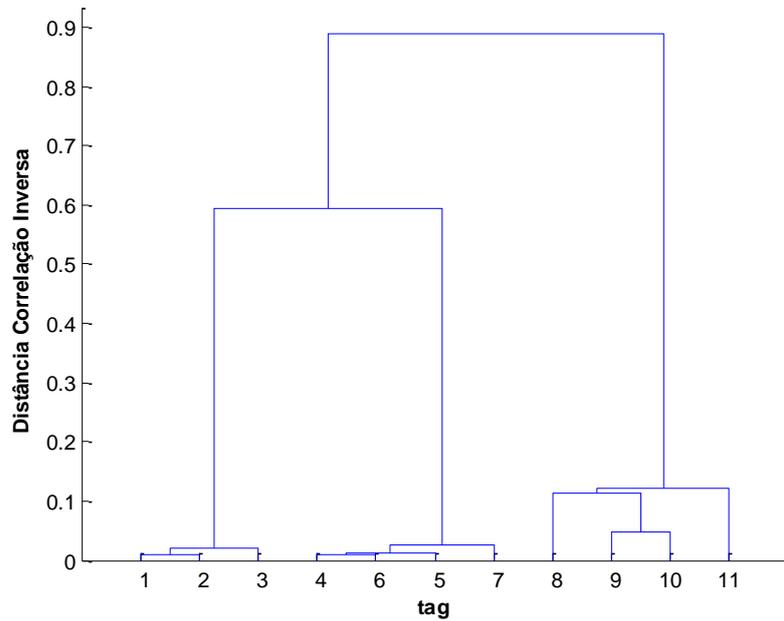


Figura 39. Dendrograma obtido a partir das variáveis do processo da seção de óleo térmico utilizando a distância da correlação inversa.

Conforme entendimento do processo, espera-se maior afinidade entre as *tag1*, *tag2* e *tag3*, entre as *tag4*, *tag5*, *tag6* e *tag7* e, finalmente, entre as *tag8*, *tag9*, *tag10* e *tag11*. Observa-se que, embora as distâncias calculadas tenham sido diferentes, as duas técnicas foram capazes de agrupar o conjunto de dados original em três conjuntos.

As Figuras 40 e 41, elaboradas com auxílio do *software* MATLAB®, apresentam os dendogramas (para a distância Euclidiana e correlação inversa, respectivamente) construídos a partir das ocorrências dos alarmes quando os valores dos *setpoints* são alterados para os valores da média apresentados na Tabela 18. Observa-se que, novamente, os mesmos três grupos foram formados apesar das distâncias calculadas terem sido diferentes. Portanto, para o caso apresentado, parece não haver motivos para a existência de um alarme para cada variável de processo, mas sim de um alarme para cada grupo de variáveis de processo, sugerindo a simplificação da rotina de monitoramento dos alarmes.

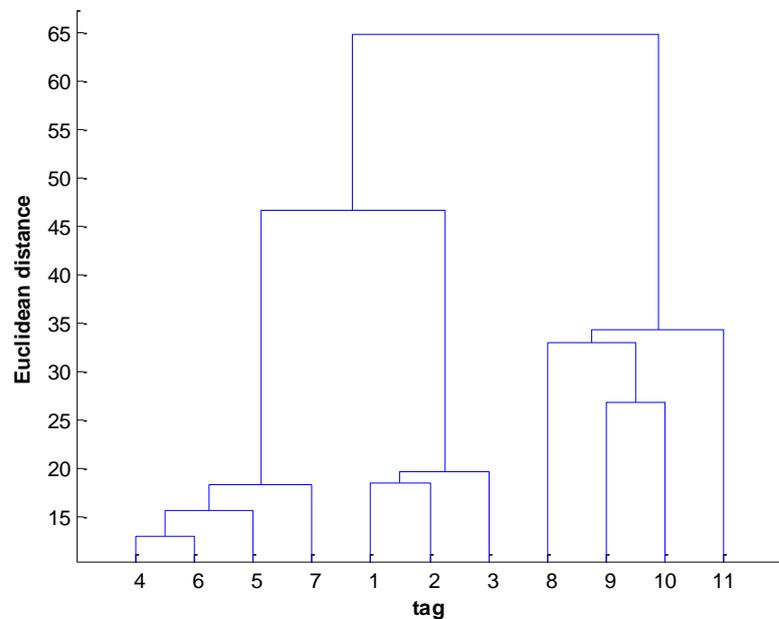


Figura 40. Dendograma obtido a partir dos alarmes da seção de óleo térmico utilizando a distância Euclidiana.

Conforme discutido no Capítulo 2 deste trabalho, a análise de componentes principais é uma técnica estatística muito utilizada para a redução da dimensionalidade dos dados sem, contudo, perda significativa das informações. Neste sentido, esta ferramenta poderia ser utilizada para validar os resultados obtidos com o mapa de cores e com a análise de agrupamentos. As Figuras 42 e 43, elaboradas com auxílio do *software* MATLAB®, apresentam os resultados da análise de componentes principais aplicada aos dados das variáveis do processo e dos alarmes, respectivamente.

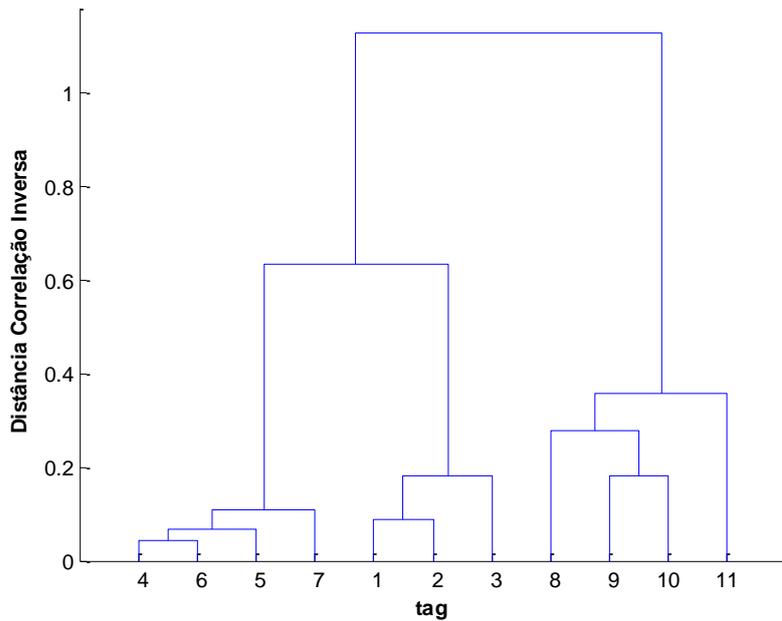


Figura 41. Dendrograma obtido a partir dos alarmes da seção de óleo térmico utilizando a distância da correlação inversa.

A Figura 42 sugere que as 11 variáveis originais podem ser reduzidas para apenas 3 (capacidade de representar a variabilidade original do sistema acima de 95%), sendo estas as médias da pressão, da temperatura e da vazão. Não é possível calcular a matriz de correlação dos alarmes se não há registro de ocorrências. Por isto, a análise de PCA apresentada na Figura 42 foi construída para os valores *setpoint* definidos com base nos valores médios das variáveis do processo apresentados na Tabela 18.

A Figura 43 mostra que apenas 6 alarmes teriam a capacidade de representar a variabilidade original do sistema acima de 95%. Estes alarmes seriam as médias da pressão, temperatura e vazão, mais um alarme de cada variável de processo. O uso de 6 alarmes já seria uma simplificação do sistema atual, já que o mesmo possui 11 alarmes, no entanto, deve-se destacar que as 3 primeiras componentes principais já conseguem representar em 88% a variabilidade total do sistema. Portanto, poderiam ser utilizadas apenas estas 3 alarmes para o monitoramento do sistema.

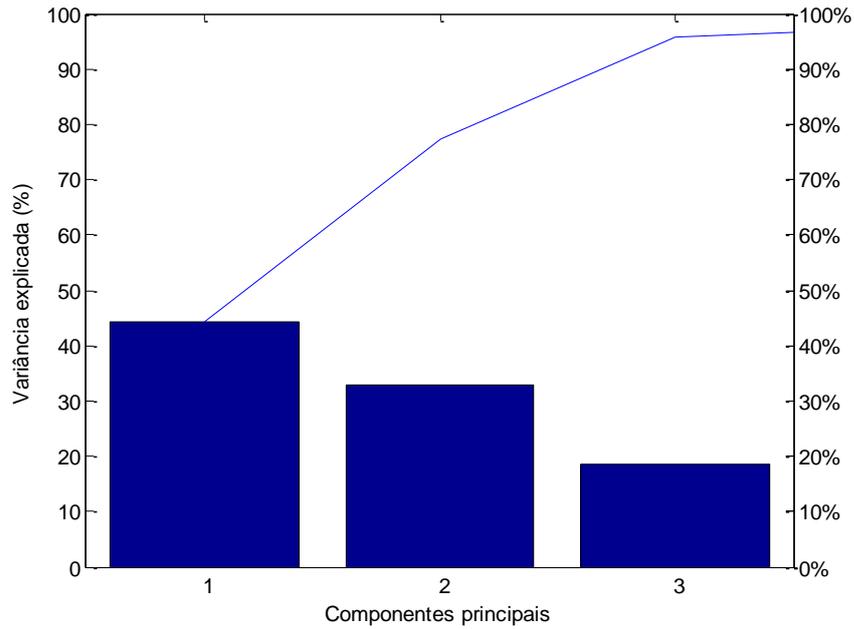


Figura 42. Análise das componentes principais das variáveis do processo da seção do forno de óleo térmico.

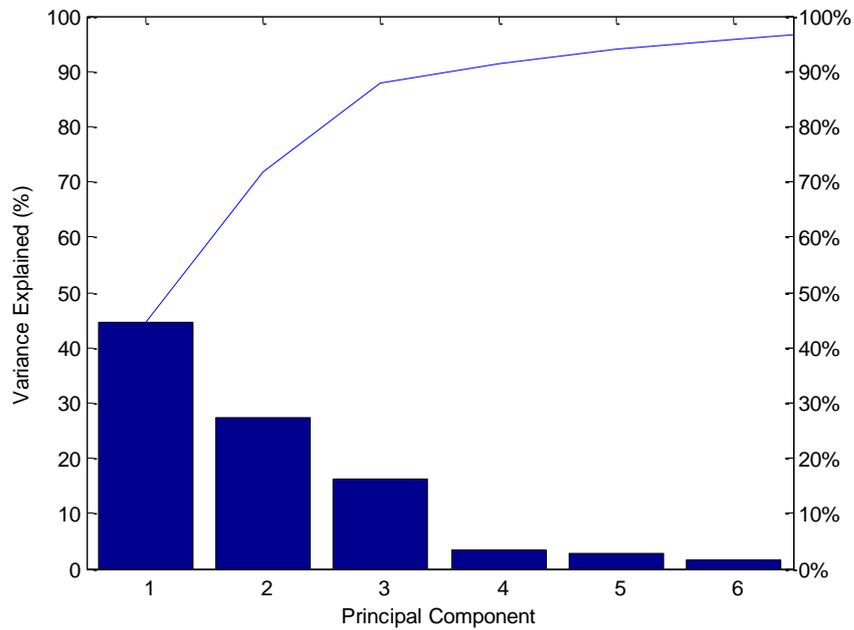


Figura 43. Análise de componentes principais das ocorrências de alarmes da seção do forno de óleo térmico.

Propor a substituição dos alarmes originais pelos alarmes do tipo PCA pode se tornar uma tarefa bastante desgastante dentro do “chão de fábrica”, em função da fácil compreensão que se tem dos alarmes originais e do pouco conhecimento que se tem da ferramenta de análise. Além disso, existe a falsa impressão de que quanto mais alarmes

configurados, mais seguro está o processo. Por tudo que já foi apresentado e discutido até o presente momento neste trabalho este é um paradigma que precisa ser quebrado. Dito isto, uma alternativa proposta neste trabalho é manter os alarmes originais do sistema e, em uma camada acima da camada de alarmes, estabelecer uma nova camada de segurança formada pelos alarmes do PCA. Esta camada ficaria “escondida” dos operadores de maneira que apenas o alarme seria acionado caso o *setpoint* fosse estabelecido. Neste sentido, pode-se utilizar a estatística T^2 de Hotelling (Equação 26) e o limite de controle superior (Equação 27) como ponto de atuação do alarme.

3.6.2. Caso 2: sistema de refrigeração a propano

Motivado pelo caso anterior, o estudo de correlação dos alarmes e das variáveis de processo foi estendido para um sistema um pouco maior. A Figura 44 ilustra o circuito fechado do ciclo de refrigeração a propano da planta. O sistema dispõe de dois compressores de propano C-01A/B, sendo que em operação normal apenas um dos compressores permanece em operação. O propano líquido proveniente do vaso acumulador de propano (V-09) flui para o desidratador de propano (S-01) para eliminar possíveis vestígios de água. A finalidade da bota do V-09 é reter óleo possivelmente arrastado do compressor e o propano líquido flui para o vaso economizador de propano (V-13). Este fluxo passa através da serpentina do vaso de sucção do compressor de propano (V-10) para evaporar qualquer resíduo de propano líquido que possa danificar seriamente o compressor em operação.

A serpentina também é utilizada para aquecer o gás propano antes que ele entre nos compressores. A válvula de controle de nível LV-605 reduz a pressão e a temperatura do propano, produzindo uma fase gasosa no V-13. O gás que deixa os vasos V-10 e V-13 flui para o compressor de propano em operação. Um eliminador de névoa tipo tela de arame localizado na saída de topo desses vasos assegura que nenhum líquido seja conduzido para o compressor. O líquido remanescente do V-10 é drenado no próprio vaso, enquanto o líquido remanescente do V-13 flui para *chiller* (P-02). A válvula de controle de nível LV-217 reduz a pressão do propano até o porto de orvalho especificado. O fluxo de duas fases entra no casco do *chiller* onde se vaporiza conforme troca calor com o gás úmido que flui através dos tubos. O gás que entra nos tubos é o próprio gás natural a ser processado na planta. Os vapores do propano que deixam o *chiller* fluem para o V-10. Os compressores de propano se encarregam de comprimir o gás propano.

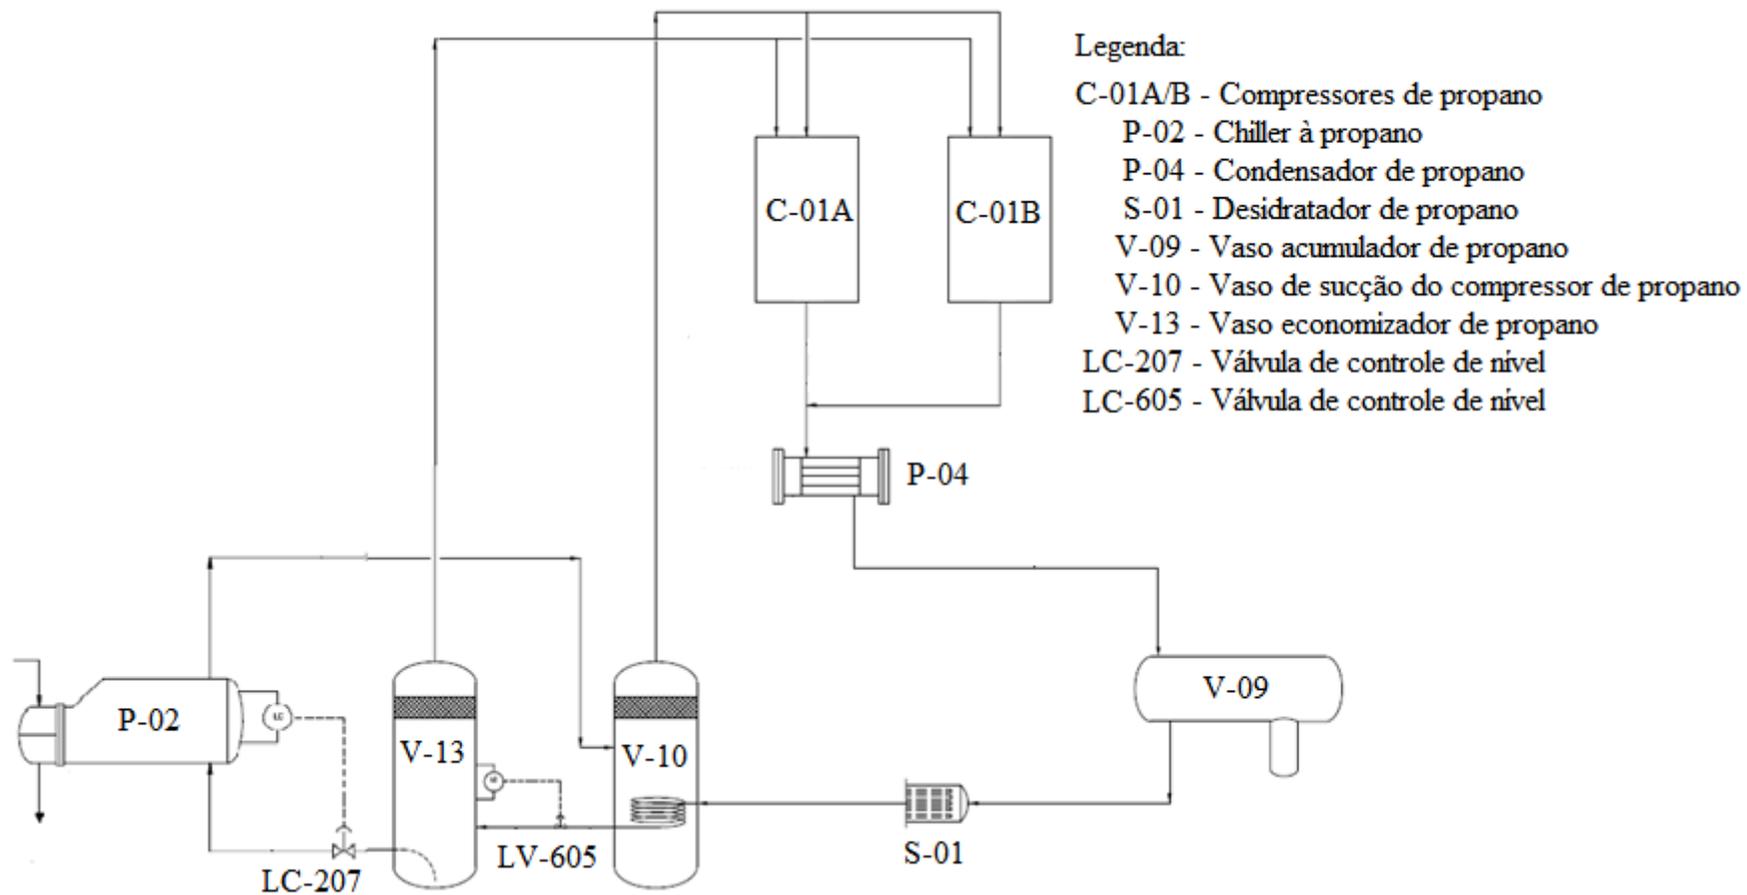


Figura 44. Fluxograma simplificado do sistema de refrigeração a propano.

A Tabela 20 apresenta as vinte variáveis do processo consideradas mais importantes pelos operadores para monitoramento do sistema de refrigeração a propano.

Tabela 20. Variáveis mais importantes para monitoramento operacional do sistema de refrigeração a propano.

Variável	Descrição	Variável	Descrição
Var1	Vazão do gás de venda	Var11	Nível no V-1238009
Var2	Temperatura saída do P-123802	Var12	Nível na bota do V-1238009
Var3	Dif. pressão no P-123802	Var13	Temperatura saída do P-1238005
Var4	Temperatura do P-123802	Var14	Pressão no V-123809
Var5	Pressão no P-123802	Var15	Temperatura no V-1238009
Var6	Pressão no P-123802	Var16	Temperatura gás combustível
Var7	Nível no casco do P-123802	Var17	Pressão gás combustível
Var8	Nível no V-1238013	Var18	Pressão sucção do C-1238001B
Var9	Nível no V-1238013	Var19	Pressão descarga do C-1238001B
Var10	Pressão no V-1238013	Var20	Status do C-1238001B

Para monitorar estas variáveis de processo, o sistema de propano possui alarme de alta (HI) e de baixa (LO) configurados, conforme indicado na Tabela 21. Os valores de *setpoint* informados representam os valores originais obtidos da planta.

Tabela 21. Valores originais dos *setpoints* de alarmes configurados no sistema de refrigeração a propano.

Alarme	HI	LO	Unidades	Alarme	HI	LO	Unidades
<i>tag1</i>	-	53.000	Nm ³ /d	<i>tag11</i>	77	-	%
<i>tag2</i>	-27	-	°C	<i>tag12</i>	75	-	%
<i>tag3</i>	50	-	kPa	<i>tag13</i>	50	-	°C
<i>tag4</i>	-	-35	°C	<i>tag14</i>	1.830	-	kPa
<i>tag5</i>	300	-	kPa	<i>tag15</i>	52	-	°C
<i>tag6</i>	96	-	kPa	<i>tag16</i>	-	5	kPa
<i>tag7</i>	79	-	%	<i>tag17</i>	837	-	kPa
<i>tag8</i>	92	-	%	<i>tag18</i>	-	15	kPa
<i>tag9</i>	-	27	%	<i>tag19</i>	-	50	kPa
<i>tag10</i>	580	-	kPa	<i>tag20</i>	-	-	-

Diferentemente do caso do sistema do forno de óleo térmico, nesta secção todos os valores de *setpoint* de alarmes serão mantidos fixos. As correlações das variáveis de processo e dos alarmes serão investigadas em três cenários de falhas distintos (e que de fato parecem ocorrer na planta com maior frequência) e em situação de operação normal.

- Cenário 1: Operação normal de operação do sistema

Em operação normal mantém-se apenas um compressor de propano em operação com uma vazão média de gás exportado de 1.563.083,72 Nm³/dia (ou 65.129 Nm³/h). A Tabela 22 apresenta os valores médios das demais variáveis de processo monitoradas.

Tabela 22. Valores médios das variáveis de processo em operação normal no sistema de refrigeração a propano.

Variáveis	Média	Unidades	Variáveis	Média	Unidades
Var1	1.563.083,72	Nm ³ /d	Var11	30,53	%
Var2	-31,26	°C	Var12	14,82	%
Var3	5,79	kPa	Var13	32,95	°C
Var4	-32,84	°C	Var14	1.099,29	kPa
Var5	46,07	kPa	Var15	33,90	°C
Var6	48,11	%	Var16	25,24	°C
Var7	50,19	%	Var17	722,82	kPa
Var8	41,54	%	Var18	546,43	kPa
Var9	45,00	%	Var19	11.287,61	kPa
Var10	549,87	kPa	Var20	-	-

As Figuras 45 e 46 mostram os mapas de cores das variáveis de processo e dos alarmes em período caracterizado pela operação normal, respectivamente. Os nomes “Var” e “tag” foram omitidos dos mapas para facilitar a legibilidade do gráfico, mas deve-se entender que o número *i* refere-se à Vari ou *tagi*. Observa-se na Figura 45 que algumas correlações significativas são identificadas no mapa de cores. É o caso, por exemplo, das variáveis Var2-Var15, Var2-Var16, Var5-Var18, Var7-Var12, Var7-Var15, Var7-Var16, Var8-Var9, Var10-Var13, Var12-Var15, Var12-Var16, Var13-Var10, Var13-Var14, Var13-Var19, Var14-Var19 e Var15-Var16. Não houve ativações de alarmes em situação de operação normal, por isto, o mapa de cores apresentado indica a máxima correlação positiva entre estes sinais.

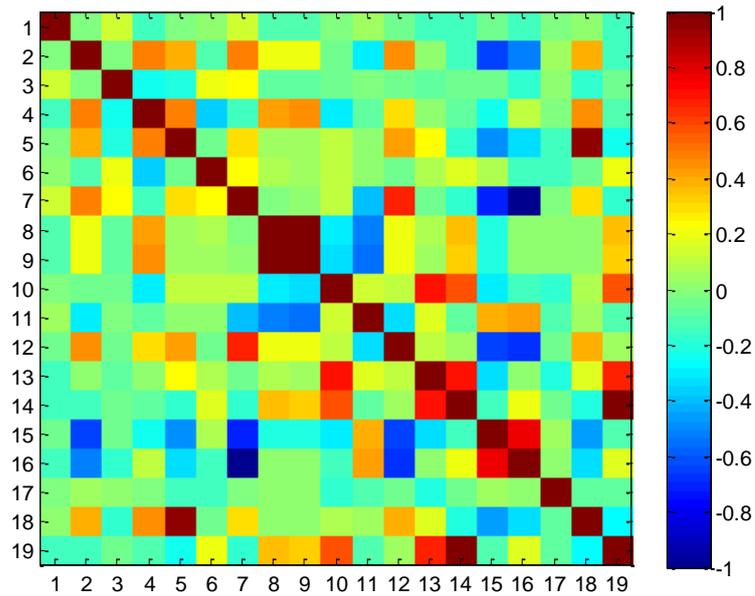


Figura 45. Mapa de cores das variáveis de processo do sistema de refrigeração a propano em período caracterizado como operação normal da planta.

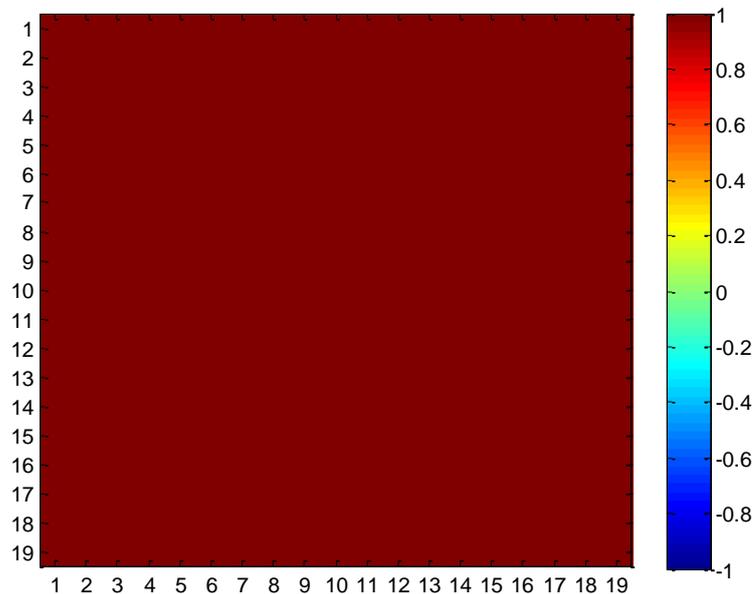


Figura 46. Mapa de cores dos alarmes do sistema de refrigeração a propano em período caracterizado como operação normal da planta.

- Cenário 2: Parada do compressor de propano

Por ser o principal equipamento do ciclo de refrigeração, falhas no compressor de propano podem causar a perda de especificação do gás de venda. Portanto, a qualidade do propano refrigerante sempre deve ser analisada. Propano refrigerante de baixa

qualidade pode afetar todo o ciclo de refrigeração, gerando problemas operacionais nos compressores, como pressão muito alta ou muito baixa na descarga da máquina. Isto poderia causar a parada desses equipamentos. Outra situação que provocaria a parada do compressor de propano seriam os problemas elétricos. De acordo com os operadores, a parada do compressor de propano provoca aumento de pressão no *chiller*.

As Figuras 47 (a), (b) e (c) apresentam o comportamento do *status* do compressor de propano (0 - desligado; 1 - ligado), da pressão no *chiller* (medida em kPa) e do alarme de pressão alta (com *setpoint* no valor de 300 kPa). Nota-se que nas proximidades do instante de 200 minutos, o compressor de propano (Var20) foi desligado e a pressão do *chiller* subiu subitamente, ultrapassando o valor do *setpoint* de alarme. Nas proximidades do instante de 250 minutos o compressor de propano retomou sua condição de operação e a pressão do *chiller* voltou a cair.

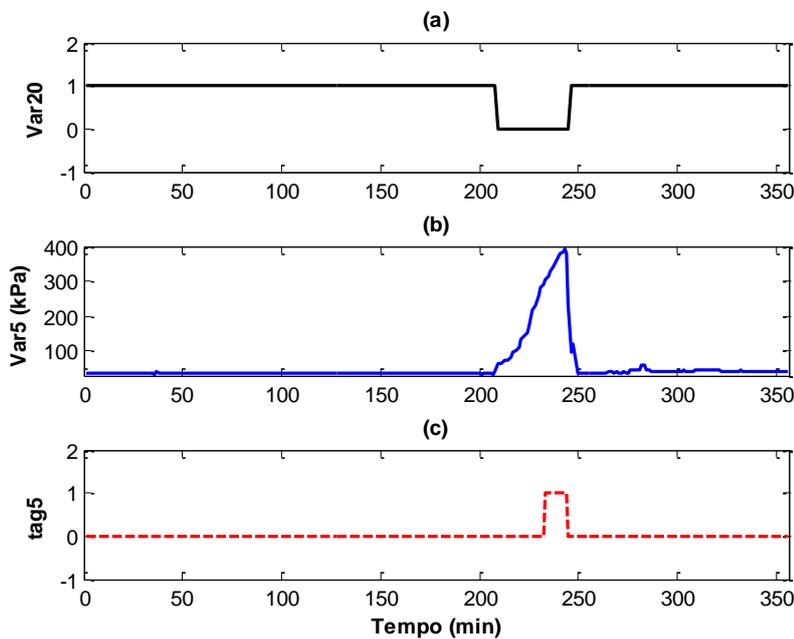


Figura 47. Relação entre as variáveis de processo Var20 e Var5 e o alarme tag5 do sistema de refrigeração a propano.

As Figuras 48 e 49 apresentam o resultado do mapa de cores das variáveis de processo e dos alarmes em períodos caracterizados pela parada do compressor de propano. Nota-se que, nesta situação tanto as correlações das variáveis de processo, quanto as correlações dos alarmes são diferentes daquela mostrada no caso anterior.

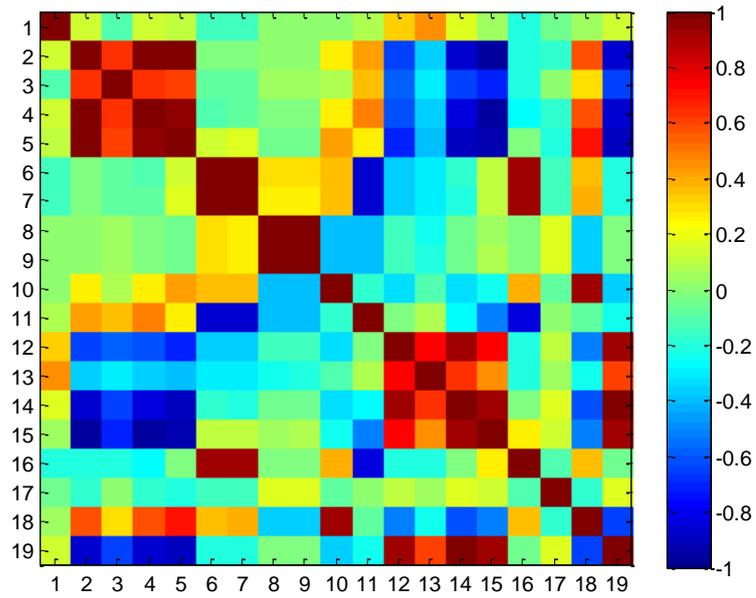


Figura 48. Mapa de cores das variáveis de processo do sistema de refrigeração a propano na parada do compressor de propano.

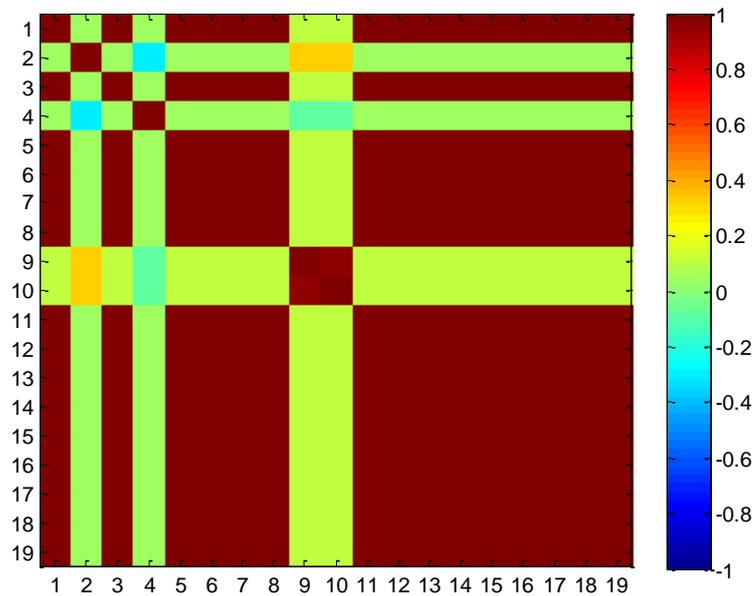


Figura 49. Mapa de cores dos alarmes do sistema de refrigeração a propano na parada do compressor de propano.

- Cenário 3: Parada do compressor de venda

A parada da planta (evidenciada pelo interrompimento da vazão do gás exportado) reduz a quantidade de vapor gerada no *chiller*, em função da menor quantidade de massa de gás natural para trocar calor com a corrente de propano. Conseqüentemente, a pressão no *chiller* também é reduzida.

As Figuras 50 (a), (b), (c) e (d) mostram a vazão de exportação do gás, a pressão no *chiller*, o alarme de vazão baixa do gás de exportação e o alarme de pressão alta no *chiller*, respectivamente. Observa-se que nas proximidades do instante de tempo de 170 minutos a planta encontrava-se parada e a pressão no *chiller* com uma tendência de crescimento. Nesta situação, os dois alarmes estavam em estado alarmado. Entre os instantes de tempo de 170 a 230 minutos a planta iniciou processo de operação. Durante este intervalo ambos os alarmes deixaram o estado ativado, pois houve aumento da vazão de gás exportado e redução da pressão do *chiller*. Na seqüência, a planta tornou a parar a exportação de gás e o alarme de vazão voltou a condição de ativado.

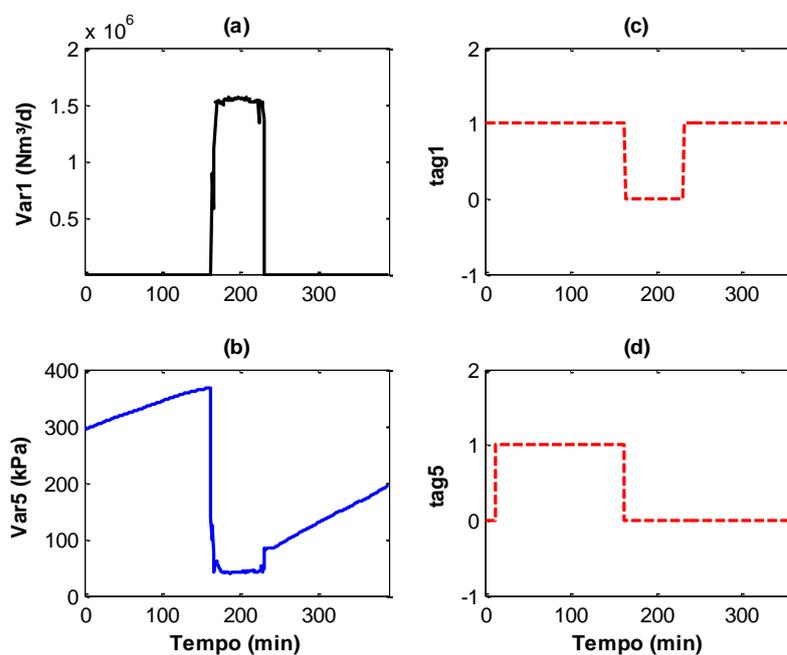


Figura 50. Relação entre as variáveis de processo Var1 e Var5 e os alarmes tag1 e tag5 do sistema de refrigeração a propano.

As Figuras 51 e 52 apresentam o resultado do mapa de cores das variáveis de processo e dos alarmes em períodos caracterizados pela parada da planta. Quando comparado com os dois casos anteriormente apresentados verifica-se que, novamente, as

correlações das variáveis de processo e dos alarmes sofreram alterações. Isto sugere que as dinâmicas envolvidas na planta afetam diretamente as correlações investigadas.

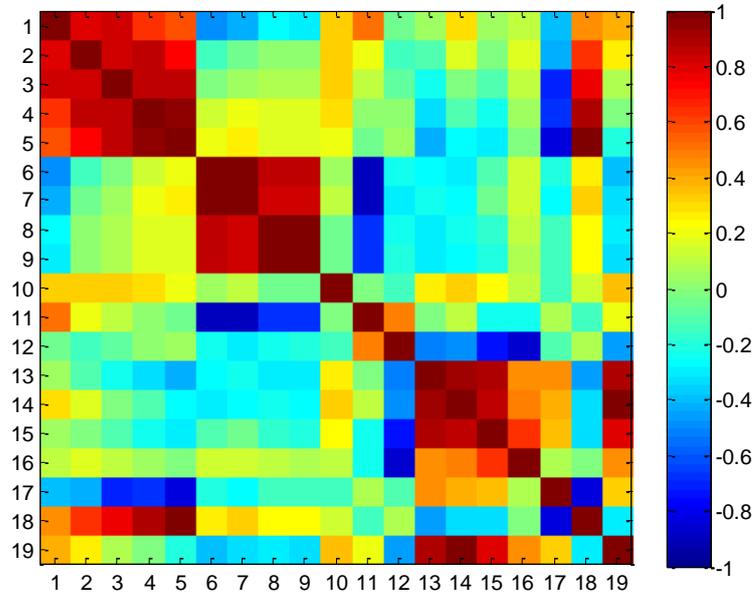


Figura 51. Mapa de cores das variáveis de processo do sistema de refrigeração a propano na parada da planta.

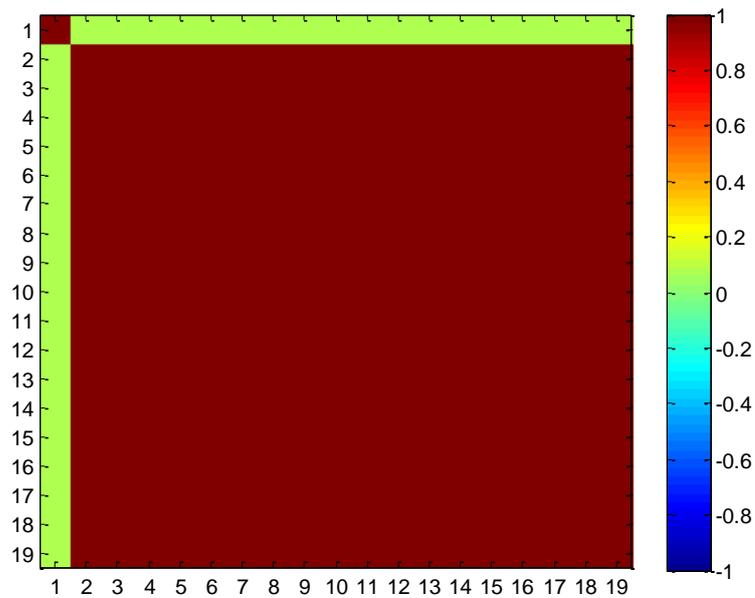


Figura 52. Mapa de cores dos alarmes do sistema de refrigeração a propano na parada da planta.

- Cenário 4: Instabilidade na malha de controle

O vaso economizador de propano (V-13) possui controle de nível e controle de pressão. Este vaso é a maior fonte de oscilações do sistema de propano por ser um vaso de pequena capacitância e possuir válvulas de controle acopladas. Ao longo do dia, ajustes nos *setpoints* de controle são necessários devido à influência da temperatura externa no vaso, que faz elevar a pressão durante o dia e diminuir durante a noite.

As Figuras 53 (a), (c) e (d) mostram o comportamento oscilatório das variáveis de processo Var9, Var10 e Var14, respectivamente, ao passo que as Figuras 53 (d), (e) e (f) ilustram o estado normal dos alarmes *tag9*, *tag10* e *tag14*, respectivamente. Observa-se que os valores atuais dos *setpoints* de alarmes são incapazes de detectar oscilações nas malhas de controle, o que dificulta a percepção do evento pelos operadores.

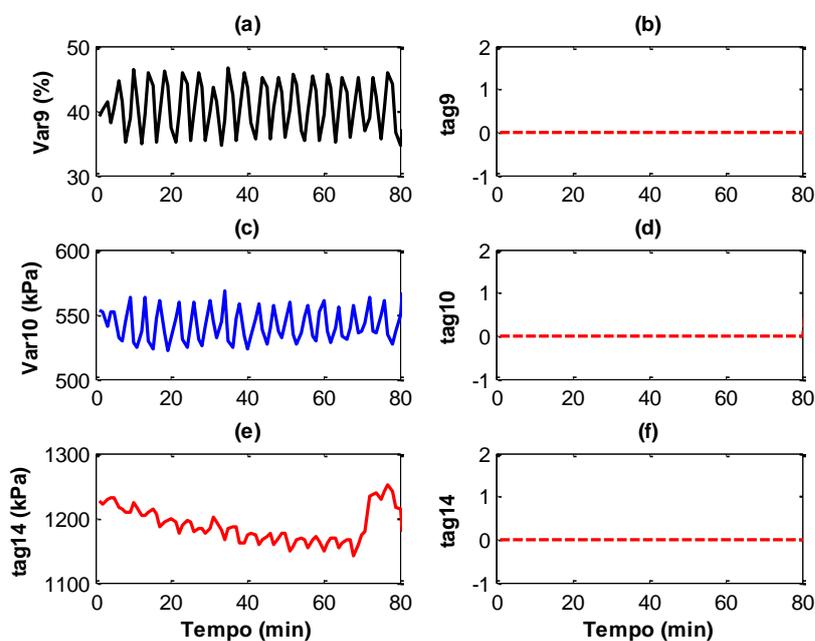


Figura 53. Relação entre as variáveis de processo Var9, Var10 e Var14 e os alarmes *tag9*, *tag10* e *tag14* do sistema de refrigeração a propano.

As Figuras 54 e 55 apresentam o resultado do mapa de cores das variáveis de processo e dos alarmes em períodos caracterizados por oscilações na malha de controle. Mais uma vez verifica-se que as correlações entre as variáveis de processo foram alteradas em função do evento ocorrido na planta. Apesar disso, o evento não foi suficiente para gerar sinais de alarmes, fazendo com que o mapa de cores dos alarmes permanecesse na condição de máxima correlação positiva possível.

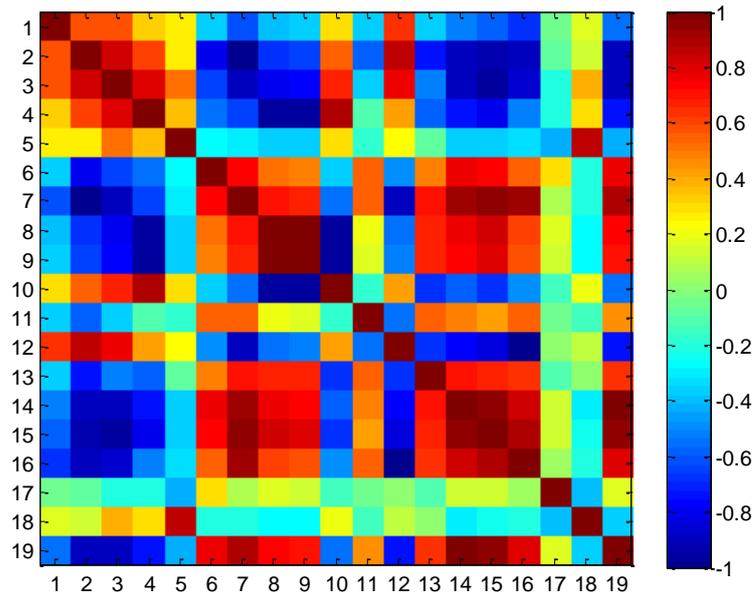


Figura 54. Mapa de cores das variáveis de processo do sistema de refrigeração a propano para oscilações na malha de controle.

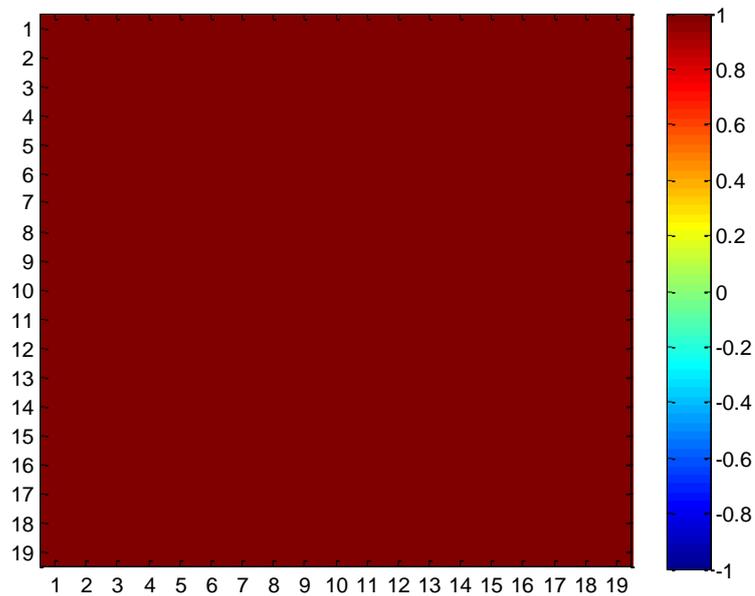


Figura 55. Mapa de cores dos alarmes do sistema de refrigeração a propano para oscilações na malha de controle.

Em função de todos os resultados apresentados, pode-se afirmar que as correlações entre as variáveis de processo e entre os alarmes são dinâmicas e mudam conforme os eventos de processo. Isso certamente reflete o caráter multivariável e não

linear de operação, tornando menos óbvia a existência de correlações fortes e persistentes ao longo de todo range de operação. Além disso, observa-se que as correlações dos alarmes não são necessariamente iguais às correlações das variáveis de processo. Vários fatores podem contribuir para isto, como os valores de *setpoint* configurados, a presença de *delay time*, *filtering*, *deadband*, entre outras questões.

3.7. Considerações Finais

Apesar dos variados tipos de problemas que podem existir em sistema de alarmes de planta industriais modernos, o número excessivo de ativações de alarmes parece ser o problema mais evidente. Na literatura existem diversas ferramentas capazes de identificar problemas em sistema de alarmes, no entanto, até o presente momento, não foi identificado nenhuma metodologia capaz de abordar estas técnicas de forma sistemática. Neste sentido, o presente capítulo apresentou o desenvolvimento e a aplicação do, aqui chamado, protocolo de gerenciamento de alarmes. O mecanismo, configurado acima da camada do Sistema Supervisório de Controle e Aquisição de Dados (SCADA), integrou diferentes ferramentas estatísticas para identificar pontos de melhorias no sistema de alarmes. O protocolo foi aplicado em um estudo de caso real numa Unidade de Processamento de Gás Natural (UPGN) e se mostrou bastante promissor, reduzindo as ocorrências do número de alarmes em mais de 50%. Apesar disso, as práticas adotadas neste trabalho não devem ser entendidas como a única maneira de propor melhorias em sistemas de alarmes. Obviamente, cada planta tem suas particularidades, tecnologias, profissionais, objetivos, nível de comprometimento da alta gerência, desafios, entre outras questões que influenciam diretamente no resultado obtido com as práticas de gerenciamento de alarmes.

Além da estrutura proposta, considera-se também como inovador o fato do protocolo utilizar mapa de cores, análise de agrupamentos e análise de componentes principais para identificar variáveis do processo e sinais de alarmes correlacionados. Neste sentido, destaca-se o mapa de cores como sendo a técnica mais simples dentre as três utilizadas. Esta ferramenta está baseada na distribuição normal de probabilidade e no cálculo do coeficiente de correlação. Pela simplificada, algumas correlações fracas eventualmente não seriam identificadas neste tipo de abordagem. A análise de agrupamento, por sua vez, não faz qualquer suposição sobre a distribuição estatística dos dados e, dependendo do tipo de estratégia utilizada para cálculo das distâncias, não requer qualquer conhecimento estatístico do processo. Por ser uma técnica não-linear pode ser

capaz de identificar correlações não identificadas pelo mapa de cores. Por outro lado, seu entendimento é mais complexo e não permite identificar com clareza a possibilidade de redução do conjunto original dos dados. Já a análise de componentes principais permite reduzir o conjunto original dos dados sem perda significativa da qualidade das informações.

O uso conjunto do mapa de cores, análise de agrupamentos e análise de componentes principais podem oferecer subsídio suficiente para propor uma redução do número de alarmes configurado na planta (estratégia mais arrojada) ou a configuração de mais uma camada de segurança localizada acima do sistema supervisório (estratégia mais conservadora). Talvez um dos pontos mais interessantes deste capítulo tenha sido a constatação de que as correlações observadas para as variáveis de processo não necessariamente refletiam as mesmas correlações dos respectivos alarmes utilizados para o seu monitoramento. Vários fatores contribuem para este fato como, por exemplo, a presença de *deadband*, *delay times* e *filtering* e a presença de *setpoints* mal configurados às condições de operação. Verificou-se que essas correlações podem variar conforme o evento ocorrido na planta, possivelmente refletindo o caráter não linear de operação do processo. Apesar desse efeito complicar o esforço de simplificação, ele pode indicar que os padrões de alarmes podem identificar a condição operacional, justificando o estudo proposto no próximo capítulo.

4. ESTUDO DE CASO SIMULADO

Este capítulo apresenta um estudo de caso simulado. O objetivo fundamental perseguido é o de caracterizar a correlação existente entre o estado operacional da planta e o padrão de alarmes ativados, como sugerido no capítulo anterior. Utilizou-se um reator contínuo de tanque agitado com reação exotérmica para geração dos dados de processo e alarmes. Este tipo de reator químico pertence à classe de sistema não-lineares modelados por equações diferenciais ordinárias (EDOs), obtidas pelos balanços de massa e de energia. O sistema de EDOs utilizado foi resolvido pelo método de Runge-Kutta de 4ª ordem (PINTO e LAGE, 2001).

4.1. Metodologia Aplicada ao Estudo de Caso Simulado

A Figura 56 apresenta a visão geral das etapas da metodologia aplicada ao estudo de caso simulado. Inicialmente foi proposto um modelo para análise. As equações fenomenológicas utilizadas para a criação deste modelo, bem como os parâmetros e as condições iniciais do processo, seguem detalhadas na seção 4.2 e foram implementadas no *software* MATLAB®. A partir deste modelo foi estabelecida uma condição de operação considerada normal e foram simulados diferentes cenários de falhas envolvendo a vazão de alimentação do reator e a vazão do fluido refrigerante, conforme apresentado na seção 4.3.

O primeiro cenário investigado propõe avaliar os efeitos da presença do ruído de medição nas correlações entre as variáveis de processo. Para isto o ruído foi modelado conforme demonstrado na seção 4.3.1 e as correlações foram analisadas através do uso do mapa de cores. A presença de ruído de medição, associado a valores de *setpoint* de alarmes mal configurados, pode contribuir para elevar as taxas de ocorrências de alarmes no processo, por isto, identificar a presença de alarmes ruidosos é de fundamental importância. Neste sentido foi desenvolvido o código RL (*run length*), em VBA-Excel®, capaz de avaliar o comportamento ruidoso de um alarme. O código pode ser visto em detalhes no Apêndice 3 deste trabalho.

O segundo cenário investigado propõe a análise dos padrões de alarmes ocorridos na presença de perturbações ocorridas na vazão de alimentação do reator. Para isto o comportamento do reator foi simulado com vazões variando de 1 até 100 l/min. Da mesma forma, o terceiro cenário investigado propõe a análise dos padrões de alarmes ocorridos na presença de perturbações ocorridas na vazão do fluido refrigerante. Neste caso, o comportamento do reator foi simulado com vazões variando de 1 até 80 l/min. A condição

normal de operação considera vazão de alimentação de 100 l/min e vazão de fluido refrigerante de 80 l/min.

As simulações foram feitas no *software* MATLAB® e os resultados obtidos foram exportados para planilha Excel®. Os padrões de alarmes formados em cada cenário de falha simulados foram no próprio Excel®. O código pode ser visto em detalhes no Apêndice 4 deste trabalho. Basicamente, a geração dos padrões de alarmes envolve a identificação do momento da primeira ativação de cada alarme, bem como o tempo de duração deste sinal no processo.

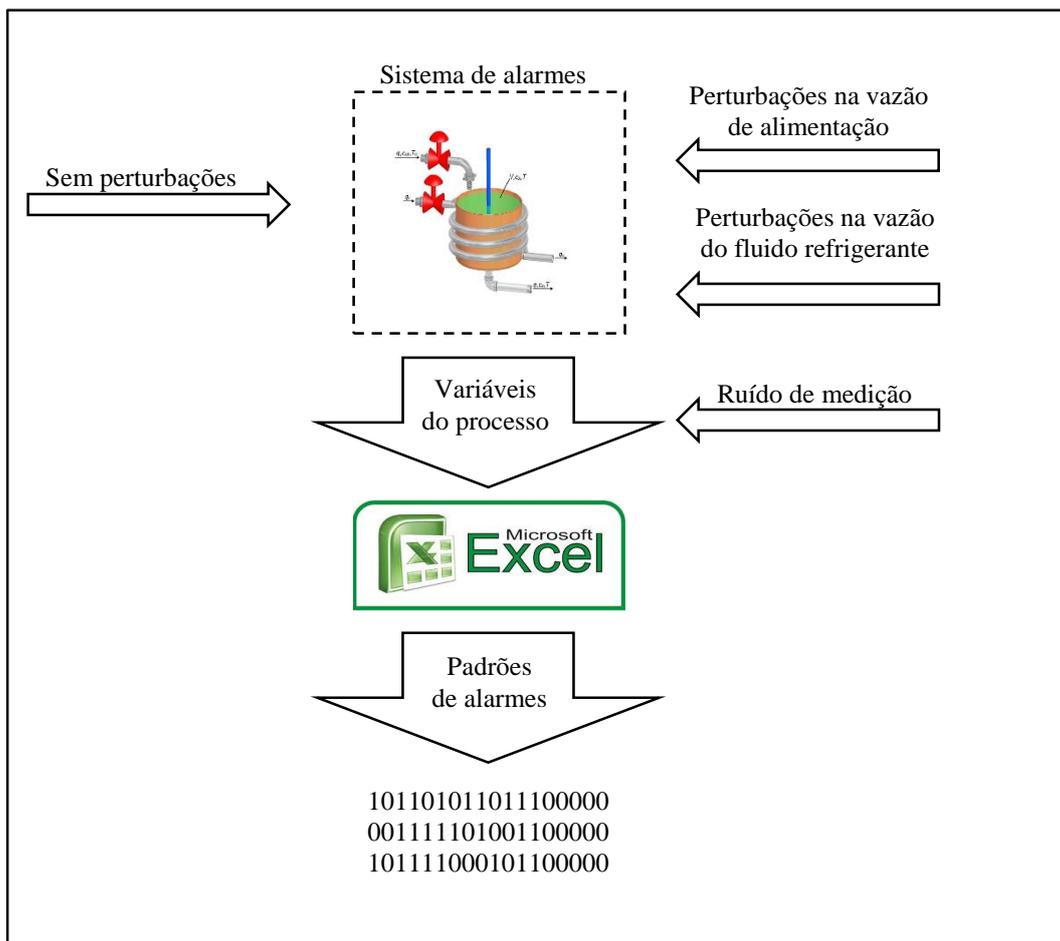


Figura 56. Visão geral das etapas da metodologia aplicada ao estudo de caso simulado.

As análises dos padrões de alarmes foram feitas sob duas perspectivas diferentes. Na primeira abordagem os padrões de alarmes foram investigados de forma estacionária, numa espécie de “fotografia” do processo. Em outras palavras, identifica-se quais alarmes foram acionados em função do cenário de falhas introduzido no processo. A ideia principal é comprovar que padrões de alarmes podem estar associados a eventos

determinísticos ocorridos no processo e, portanto, é possível diagnosticar cenários de falhas observando apenas os padrões de alarmes. Na segunda abordagem padrões de alarmes foram avaliados dinamicamente. Ou seja, busca-se mapear ordem com que estes sinais aparecem no processo em função do cenário de falha simulado. Neste caso, a ideia principal é comprovar a possibilidade de prever uma ativação de alarme com base em outra(s) ocorrida(s) anteriormente. Esta informação também seria útil sob o ponto de vista do diagnóstico antecipado de falhas no processo.

4.2. Modelo Proposto para Análise

Reatores contínuos de tanque agitado (*continuous stirred tank reactor – CSTR*) com presença de reação exotérmica são frequentemente usados para análise de problemas *benchmark* para algoritmos de controle de processo não-lineares. Parte desta vasta aplicabilidade está associada à baixa complexidade dos modelos envolvidos e à vasta aplicação industrial. A Figura 57, obtida do trabalho de Vojtesek e Dostal (2011), ilustra o sistema proposto, em que q , C_{A0} e T_0 representam a vazão, a concentração e a temperatura na corrente de alimentação do reator; q_c é a vazão do fluido de refrigeração; V , C_A e T são o volume, a concentração e temperatura no reator. Tanto a corrente de alimentação do reator, quanto a corrente do fluido refrigerante são controladas por válvulas manuais.

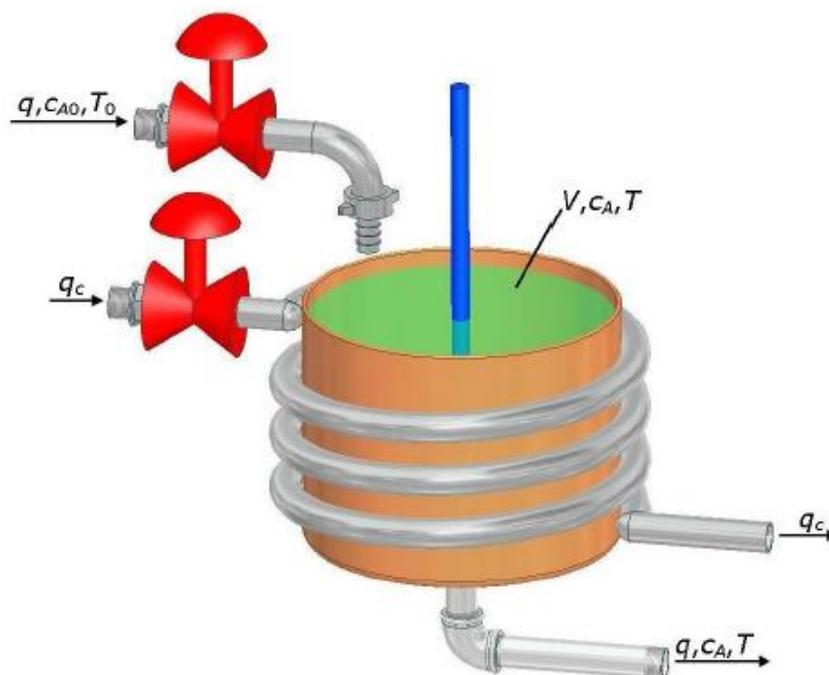


Figura 57. Reator contínuo de tanque agitado (VOJTESEK e DOSTAL, 2011).

Modelos concentrados, diferentemente dos modelos distribuídos, são aqueles em que se admite que as propriedades (concentrações, temperaturas, densidade *etc*) são uniformes no espaço (PINTO e LAGE, 2001). Em função disso, as variáveis C_A e T na corrente de saída e no interior do reator são iguais. Considerando o fluido incompressível (densidade constante), o volume do reator constante (controle de nível efetivo) e desprezando o trabalho mecânico executado pela “pá” sobre o sistema (usualmente pouco importante, quando comparado aos demais termos do balanço de energia, embora isto não seja uma regra geral), o reator pode ser modelado pelas Equações 29, 30, 31, 32, 33, 34 e 35 (VOJTESEK e DOSTAL, 2011). Em função da simplicidade do modelo, espera-se que os padrões de alarme ganhem um destaque maior do que a modelagem do processo, propriamente dita.

$$a1 = \frac{q}{V} \quad (29)$$

$$a2 = \frac{-\Delta H}{\rho \cdot C_p} \quad (30)$$

$$a3 = \frac{\rho_c \cdot C_{pc}}{\rho \cdot C_p \cdot V} \quad (31)$$

$$a4 = \frac{-UA}{\rho_c \cdot C_{pc}} \quad (32)$$

$$k = k_0 \cdot e^{\frac{-E}{R \cdot T}} \quad (33)$$

$$\frac{dC_A(t)}{dt} = a1 \cdot (C_{A0} - C_A) - kC_A \quad (34)$$

$$\frac{dT(t)}{dt} = a1 \cdot (T_0 - T) + a2 \cdot kC_A + a3 \cdot q_c \cdot \left(1 - e^{\frac{a4}{q_c}}\right) \cdot (T_c - T) \quad (35)$$

A Tabela 23 apresenta os parâmetros fixos do modelo. Portanto, durante as simulações do comportamento do processo, estes valores não foram alterados. Observe-se que alguns desses parâmetros não necessariamente deveriam ser fixos. Por exemplo,

sabe-se que a capacidade de troca térmica pode ser afetada devido a problemas de incrustação. A concentração do reagente na corrente de alimentação pode variar ao longo do processo. Ou ainda, o volume do reator pode sofrer alterações em função da falta de controle de nível ou de um controle ineficiente.

Tabela 23. Parâmetros fixos do modelo (VOJTESEK e DOSTAL, 2011).

Descrição da variável	Símbolo e valor
Volume do reator	$V = 100 \text{ l}$
Constante da taxa de reação	$K_0 = 7,2 \times 10^{10} \text{ min}^{-1}$
Energia de ativação para R	$E/R = 1,0 \times 10^4 \text{ K}$
Temperatura da alimentação	$T_0 = 350 \text{ K}$
Temperatura do fluido refrigerante	$T_{c0} = 350 \text{ K}$
Entalpia da reação	$\Delta H = -2 \times 10^5 \text{ cal/mol}$
Calor específico do meio reacional	$C_p = 1 \text{ cal/g.K}$
Calor específico do fluido de refrigeração	$C_{pc} = 1 \text{ cal/g.K}$
Densidade do meio reacional	$\rho = 1 \times 10^3 \text{ g/l}$
Densidade do fluido de refrigeração	$\rho_c = 1 \times 10^3 \text{ g/l}$
Concentração da alimentação	$C_{A0} = 1 \text{ mol/l}$
Coefficiente de troca térmica	$UA = 7 \times 10^5 \text{ cal/min.K}$

A Figura 58 mostra o comportamento do sistema para uma vazão de alimentação constante e igual a 100 l/min e uma vazão do fluido refrigerante constante e igual a 80 l/min. Observa-se que para uma temperatura do fluido refrigerante (T_c) constante e igual a 350 K a condição estacionária é estabelecida após cerca de 5 minutos de operação do reator. Desde momento em diante, mantendo o processo sobre controle a temperatura do reator permanece em 353,63 K e a concentração em 0,963 mol/l. A Figura 59, por outro lado, mostra o comportamento do sistema quando oscilações forçadamente são introduzidas na temperatura do fluido refrigerante entre os instantes de 10 a 40 minutos. Verifica-se que esta variável do processo afeta a concentração e a temperatura do reator.

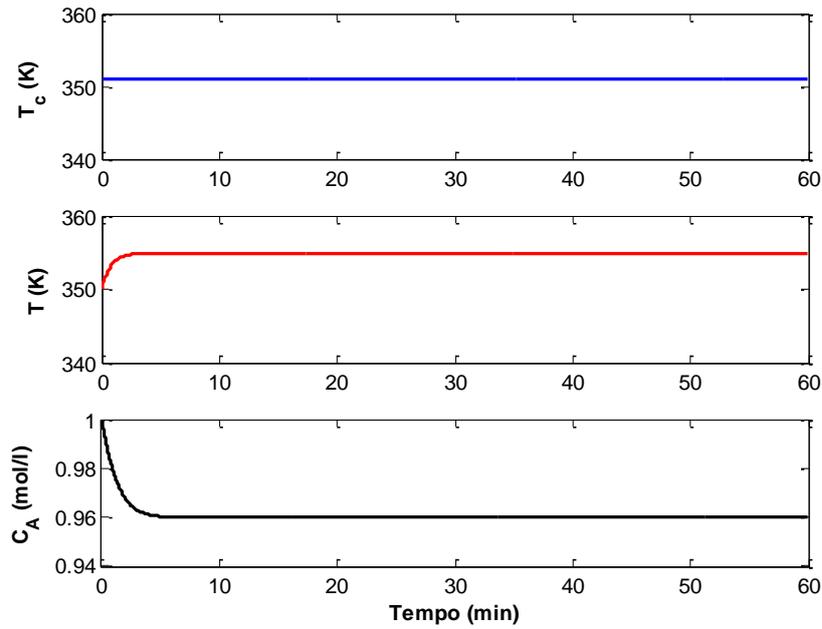


Figura 58. Comportamento do reator em condição normal de operação.

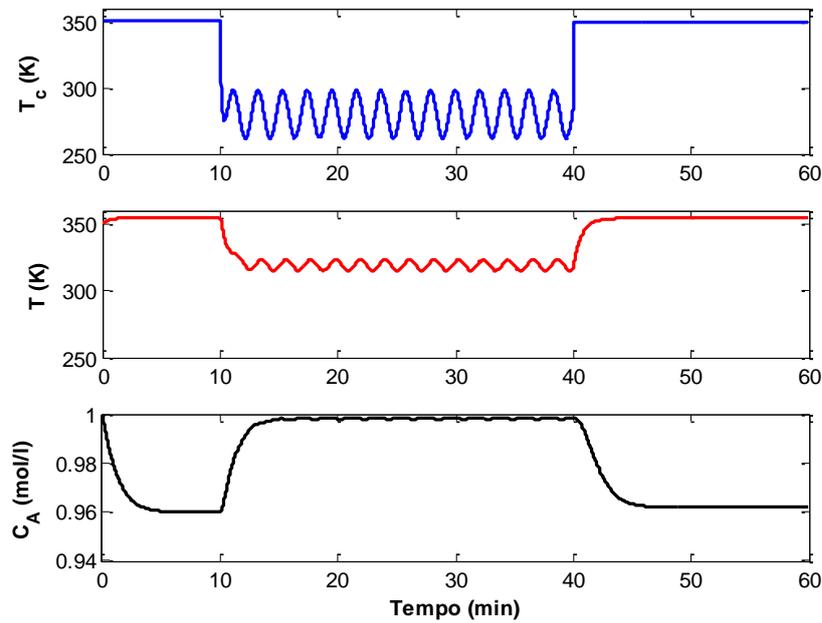


Figura 59. Comportamento do reator na presença de oscilações sustentadas em T_c .

O comportamento não-linear do sistema, em parte, está embutido na Equação (33) que é uma função não-linear da temperatura. O comportamento não-linear do sistema implica que perturbações de origens diversas podem fazer com que o processo perca estabilidade, levando-o a um estado estacionário indesejado ou a oscilar entre estados

estacionários distintos (VOJTESEK e DOSTAL, 2011). Isto sugere que estados de operação diferentes podem gerar padrões de alarmes diferentes. Portanto, sob o ponto de vista da análise dos padrões de alarmes o reator proposto apresenta, pelo menos, duas características particularmente interessantes: não linearidade e correlação.

4.3. Cenários de Falhas Testados

Conforme discutido no Capítulo 2 deste trabalho, o resultado de qualquer medição é somente uma aproximação do valor do mensurando. Isso porque as variáveis medidas e utilizadas para monitoramento podem refletir o somatório de três partes distintas: informação, ruído e falhas. Na seção 4.2 foi apresentada o comportamento normal do processo para o qual não deve ser gerado sinais de alarmes. Os cenários apresentados a seguir contemplam as outras duas situações que são: presença ruído de medição e presença de falhas no processo.

4.3.1. Eventos determinísticos: perturbações nas variáveis do processo

O uso de modelos fenomenológicos pode fornecer informações pormenorizadas do sistema, o que pode ser útil do ponto de vista dos alarmes, pois mostra que os valores dos *setpoints* a serem configurados no processo devem ser capazes de informar alterações dentro das regiões de resposta do modelo. As Figuras 60 e 61 apresentam o comportamento da temperatura e da concentração do reator, respectivamente, para vazões de alimentação de 1, 25, 50, 75 e 100 l/min. A temperatura mínima e máxima observadas foram 350 K (condição de operação normal) e 367 K (condição de menor vazão simulada) com a existência de *overshoot* na partida do reator, que aumenta com a redução do valor de q . A concentração também sofre redução conforme reduz a vazão de alimentação do reator, chegando a 0,25 mol/l para a menor vazão simulada.

As Figuras 62 e 63 mostram o comportamento da temperatura e da concentração do reator, respectivamente, para vazões de fluido refrigerante de 20, 40, 60 e 80 l/min. Como já era esperado, a temperatura do reator aumenta conforme a vazão do fluido refrigerante é reduzida e a consequência direta desse efeito é a redução da concentração. A máxima temperatura observada foi de 550 K para $q_c = 1$ l/min e, para este mesmo valor de vazão, tem-se concentração próxima de 0 mol/l no reator, indicando praticamente ausência do componente A no sistema.

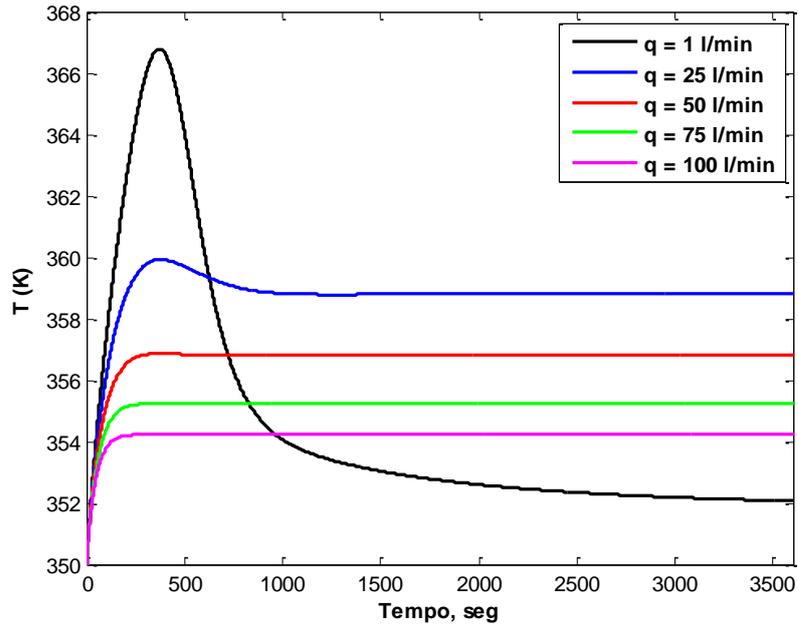


Figura 60. Variações de T em função de variações de q.

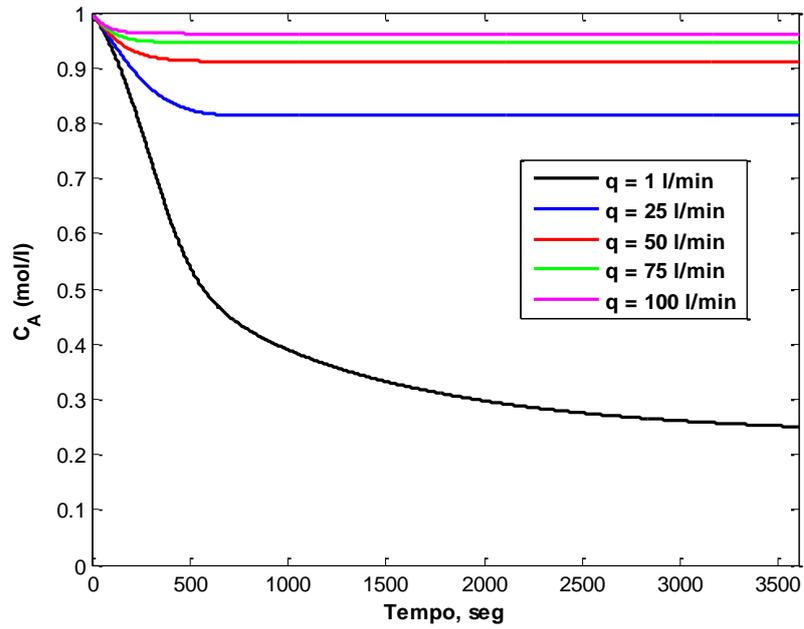


Figura 61. Variações de C_A em função de variações de q.

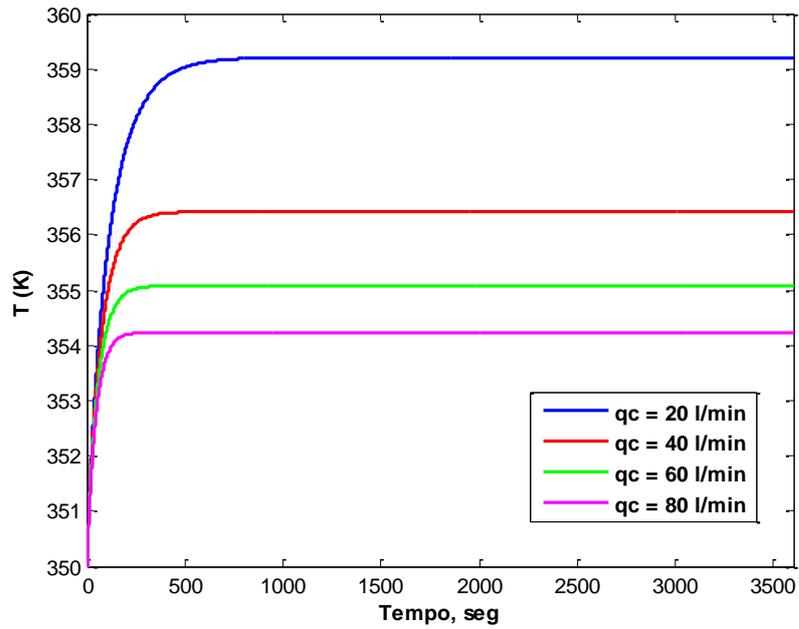


Figura 62. Variações de T em função de variações de q_c .

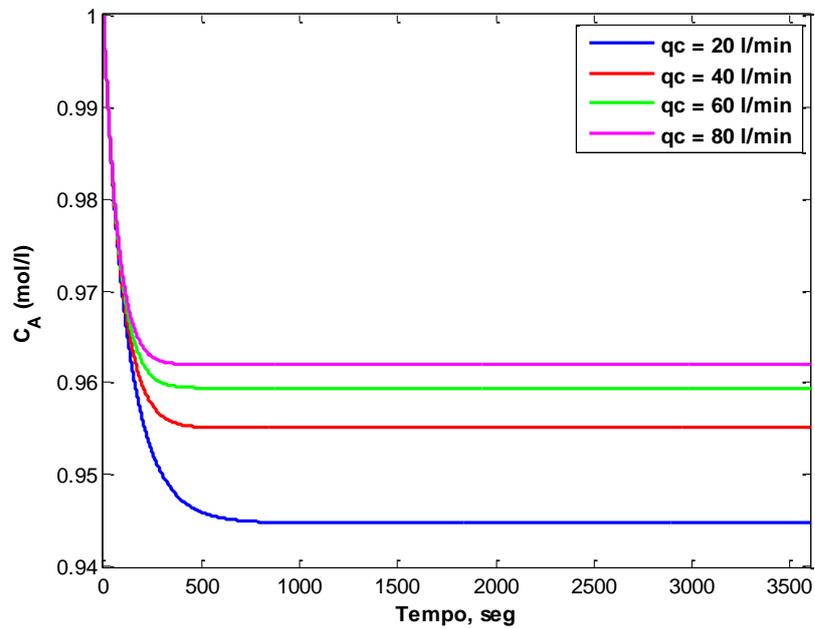


Figura 63. Variações de C_A em função de variações de q_c .

4.3.2. Eventos aleatórios: presença de ruído de medição

O ruído de medição foi modelado no *software* MATLAB® através da Equação (37), onde “a” representa a média dos valores, “b” o desvio-padrão, *randn* uma função interna do próprio MATLAB® capaz de gerar dados aleatórios distribuídos em uma matriz de “n” linhas e “m” colunas. A Figura 64 mostra o histograma obtido quando os parâmetros $a = 0$, $b = 1$, $n = 1$ e $m = 3601$ são utilizados. Os valores apresentados neste histograma foram somados a temperatura da jaqueta de resfriamento do reator (T_c).

$$\text{ruído} = a + b \cdot \text{randn}(n, m) \quad (37)$$

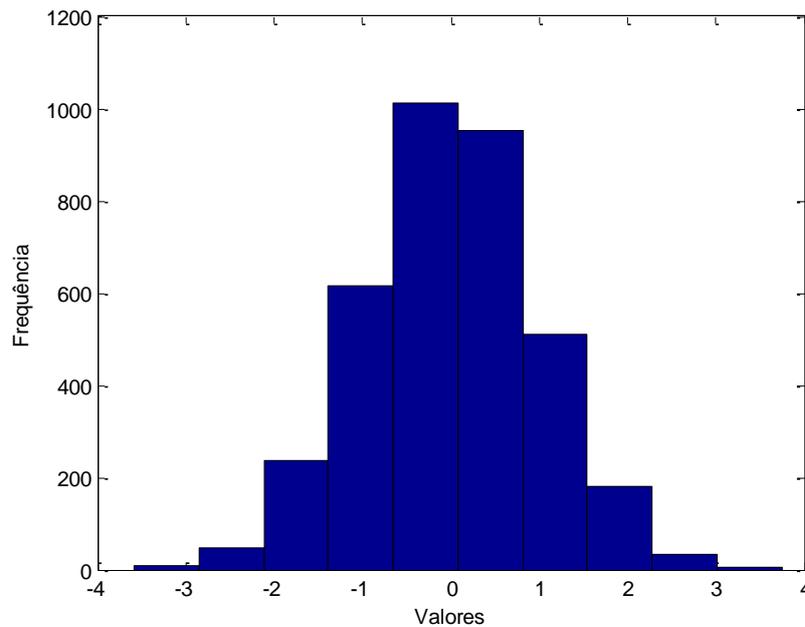


Figura 64. Histograma dos ruídos aleatórios padronizados.

A Figura 65 mostra o comportamento das três variáveis monitoradas na presença de ruído de medição na variável T_c , onde o valor mínimo observado de 346,50 K e o valor máximo observado foi de 353,41 K. Observa-se que, diferentemente do cenário apresentado na Figura 58, a presença de ruído de medição na variável T_c não parece afetar significativamente o comportamento das demais variáveis do processo. Em parte, isto se deve ao fato de não existir malhas de controle associada ao reator. Na presença de malhas de controle espera-se que o processo seja afetado, pois o controle provavelmente tentará corrigir as oscilações ocasionados pelo ruído de medição.

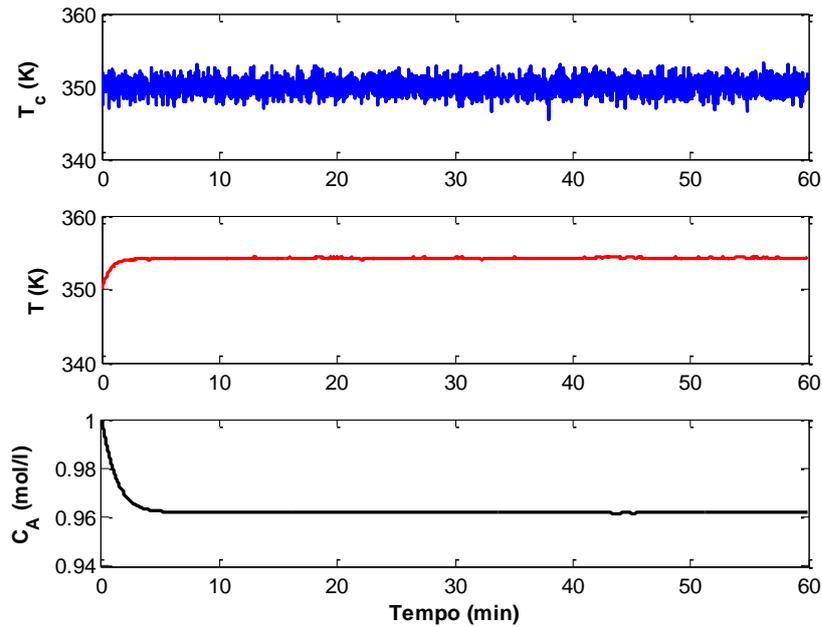


Figura 65. Presença de ruído de medição associado a variável T_c .

4.4. Análise dos Resultados

De acordo com os resultados simulados (Figura 58), a condição de operação considerada como normal prevê $T = 354$ K, $C_A = 0,96$ mol/l, $q = 100$ l/min e $q_c = 80$ l/min. Porém, em função do tipo de perturbação ocorrida no processo pode haver variações na temperatura do reator entre 350 e 550K, bem como variações de concentração entre 0 e 1 mol/l.

4.4.1. Análise dos alarmes na presença de perturbações no processo

Perturbações na vazão do fluido refrigerante parecem afetar mais significativamente o processo quando comparada com perturbações na vazão da corrente de alimentação do reator. Portanto, a temperatura e a concentração do reator, bem como a temperatura do fluido refrigerante são variáveis que precisam ser monitoradas. Inicialmente, os seguintes valores de *setpoint* foram atribuídos ao alarme de temperatura alta do reator: 350, 351, 352, 353, 354, 355, 356, 357, 358, 359, 360, 361, 362, 363, 364, 365 e 366 K. Para cada valor de *setpoint* configurado, verificou-se o momento da primeira ativação do alarme, em segundos, para os seguintes valores de vazão de alimentação do reator: 1, 25, 50, 75 e 100 l/m.

A Tabela 24 apresenta o resultado obtido onde “-” indica que não houve ativação de alarme no processo. Observa-se que, conforme o valor do *setpoint* aumenta, o alarme demora mais para ser acionado no processo, o que decorre da definição, já que os limites de atuação do alarme são mais expansivos. No entanto, a Tabela 24 traz uma informação que não é tão trivial quanto a primeira e pode ser útil do ponto de vista prático. Nota-se que é possível identificar quanto tempo o sinal de alarme leva para ser acionado no processo, a partir do momento da perturbação.

Por exemplo, supondo que o alarme de temperatura alta esteja configurado com um *setpoint* de 355 K. Se ocorresse uma perturbação na vazão de alimentação levando-a para 75 l/min, o alarme levaria 171 segundos para ser acionado no processo. Valores de *setpoint* superior a 355 K não seriam capazes de detectar a presença de perturbações na vazão de alimentação do reator.

Tabela 24. Momento da ativação do alarme de temperatura alta do reator em função do *setpoint* configurado e da vazão de alimentação do reator.

TAH (K)	q = 1 l/min	q = 25 l/min	q = 50 l/min	q = 75 l/min	q = 100 l/min
350	1	1	1	1	1
351	13	13	13	13	14
352	24	26	27	29	31
353	37	40	44	49	58
354	50	57	66	83	132
355	65	76	97	171	-
356	80	99	149	-	-
357	96	128	-	-	-
358	113	165	-	-	-
359	132	220	-	-	-
360	151	-	-	-	-
361	171	-	-	-	-
362	193	-	-	-	-
363	216	-	-	-	-
364	241	-	-	-	-
365	271	-	-	-	-
366	307	-	-	-	-

A Tabela 25 mostra o momento da ativação do alarme de concentração baixa no reator em função do *setpoint* configurado e da vazão de alimentação do reator. Mais uma vez o resultado mostra que é possível estimar o momento da ativação do alarme a partir do tipo e da magnitude da perturbação. Observa-se que, para um valor de *setpoint* do alarme de concentração baixa no reator de 0,30 mol/l, mesmo diante de uma perturbação na vazão de entrada de 1 l/min, o sinal do alarme só seria acionado no processo após 1.956 segundos (aproximadamente 32 minutos). Ao comparar os momentos de ativação dos alarmes apresentados nas Tabelas 24 e 25 é possível perceber que a redução na vazão de alimentação do reator tende a ativar primeiramente o alarme de temperatura alta antes do alarme de concentração baixa.

Por exemplo, mantendo fixos os *setpoints* do alarme TAH em 355 K e C_{AAL} em 0,90 mol/l, e ainda uma redução de q para 1 l/min, verifica-se que o alarme TAH é acionado no processo 65 segundos após a perturbação. Já o alarme C_{AAL} é ativado após 146 segundos do momento da perturbação, portanto, 81 segundos após a ocorrência do primeiro alarme. O resultado sugere que eventos diferentes ocasionariam ativações de alarmes diferentes e em momentos diferentes. Em outras palavras, parece haver uma relação determinística entre os padrões de alarmes e os eventos ocorridos no processo.

Tabela 25. Momento da ativação do alarme de concentração baixa no reator em função do *setpoint* configurado e da vazão de alimentação do reator.

C_{AAL} (mol/l)	$q = 1$ l/min	$q = 25$ l/min	$q = 50$ l/min	$q = 75$ l/min	$q = 100$ l/min
1,00	1	1	1	1	1
0,90	146	205	-	-	-
0,80	245	-	-	-	-
0,70	333	-	-	-	-
0,60	428	-	-	-	-
0,50	571	-	-	-	-
0,40	940	-	-	-	-
0,30	1.956	-	-	-	-

As Figuras 66 e 67 mostram a frequência observada das ocorrências do alarme de temperatura alta e de concentração baixa do reator para vários valores de *setpoint* em função de variações em q . O eixo Y indica o número de observações das ocorrências do alarme e o eixo X o momento exato da 1ª ativação do alarme. Nota-se que, para maiores

valores de *setpoint* existe um menor número de ocorrências de alarmes e o momento da 1ª ativação é mais demorado.

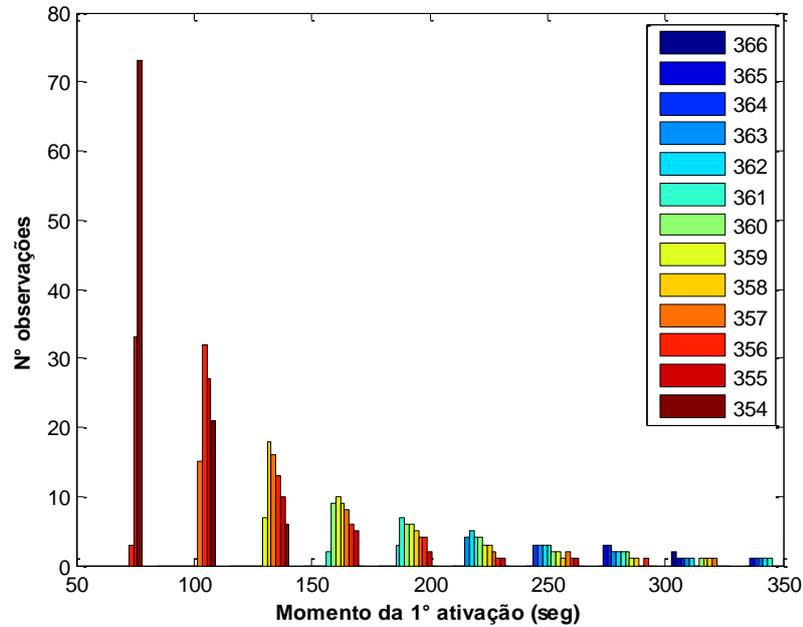


Figura 66. Frequência observada das ocorrências do alarme de temperatura alta do reator para vários valores de *setpoint* e para variações em *q*.

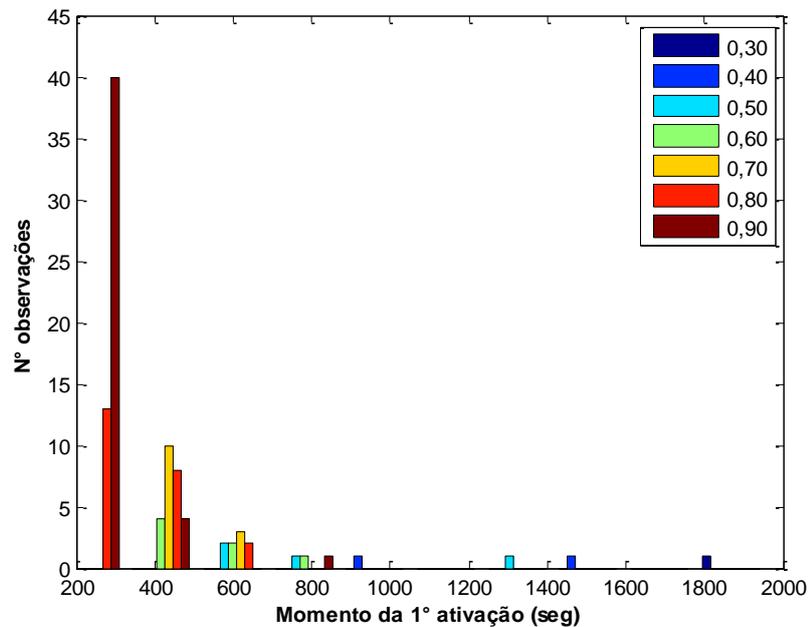


Figura 67. Frequência observada das ocorrências do alarme de concentração baixa do reator para vários valores de *setpoint* e para variações em *q*.

A Figura 68 relaciona a primeira ativação do alarme de temperatura alto do reator em função da vazão do fluido refrigerante, para um valor de *setpoint* de 354K (único valor onde ocorre ativação para todas as vazões simuladas). O modelo que melhor fez o ajuste dos pontos simulados foi o modelo exponencial apresentando coeficiente de correlação no valor de 0,9458. O resultado mostra que, para um *setpoint* fixo, é possível prever o momento da ativação do alarme com base na vazão do fluido refrigerante.

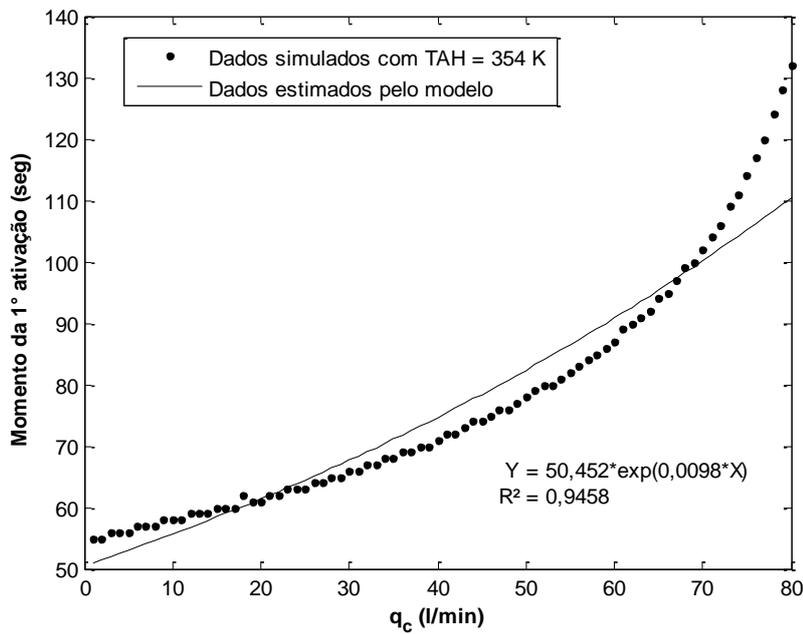


Figura 68. Modelo de predição do alarme de temperatura alta do reator para *setpoint* do alarme fixo e q_c variável.

Da mesma forma, a Figura 69 relaciona a primeira ativação do alarme de concentração baixa do reator em função da vazão do fluido refrigerante, para um valor de *setpoint* em 0,97 mol/l (único valor onde ocorre ativação para todas as vazões simuladas). O modelo que melhor fez o ajuste dos pontos simulados foi o modelo linear com coeficiente de correlação no valor de 0,9964. O resultado mais uma vez mostra que, dado um *setpoint* e uma ativação de alarme é possível estimar o momento e a causa da perturbação.

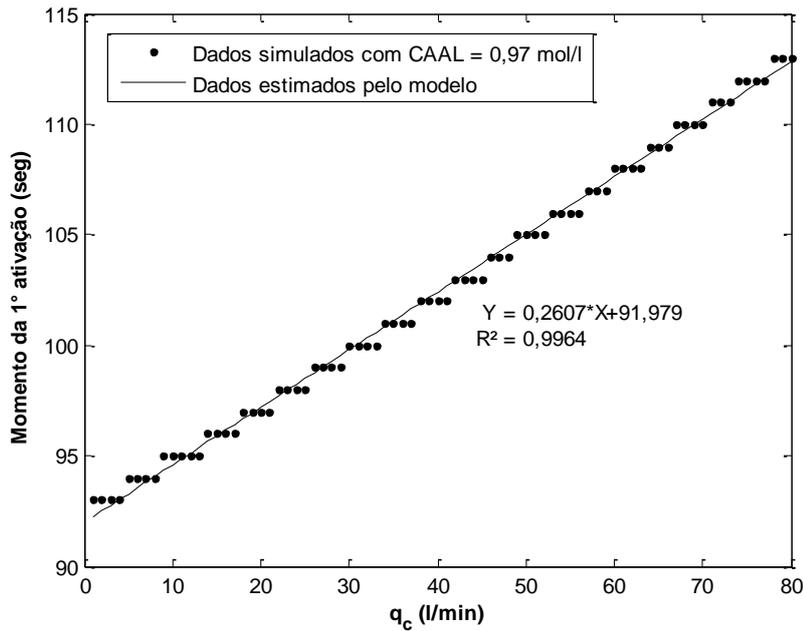


Figura 69. Modelo de predição do alarme de concentração baixa do reator para *setpoint* do alarme fixo e q_c variável.

Em função dos resultados apresentados anteriormente, parece haver uma relação determinística entre os padrões de alarmes e os eventos ocorridos no processo. Mas, quais seriam estes padrões? E, em quais momentos eles seriam anunciados na planta? Para avaliar estas questões foram estabelecidos valores fixos de *setpoint*, conforme indicado na Tabela 26. Esses valores não devem ser entendidos como os valores ótimos para o processo, mas apenas como valores adotados para avaliar os padrões de alarmes. Os padrões de alarmes forma avaliados levando-se em consideração perturbações na temperatura do fluido de refrigeração.

Tabela 26. Valores dos *setpoints* de alarmes configurados no reator.

Alarme	<i>Setpoint</i>	Unidades	Alarme	<i>Setpoint</i>	Unidades
CAAHH	0,99	mol/l	TAL	352	K
CAAH	0,98	mol/l	TALL	350	K
CAAL	0,94	mol/l	TcAHH	358	K
CAALL	0,93	mol/l	TcAH	356	K
TAHH	358	K	TcAL	352	K
TAH	356	K	TcALL	350	K

A Equação (36) poderia ser utilizada para determinar o número de combinações de alarmes possíveis no processo, sem repetição de alarmes. Neste caso, n representa o número de alarmes configurados no processo (seis) e r o número de variáveis do processo que possuem alarmes (quatro).

$$C_{r,n} = \frac{n!}{(n-r)! r!} \quad (36)$$

A Tabela 27 resume todas as possibilidades possíveis para o sistema apresentado. A primeira linha da segunda coluna (1) indica o número de diferentes combinações possíveis que podem ocorrer para o tipo de padrão indicado pela primeira linha da primeira coluna ($C_{0,12}$). Ou seja, existe apenas uma única possibilidade de não haver nenhuma ativação de alarme num universo de 12 alarmes diferentes. Por outro lado, existem 220 diferentes combinações possíveis formadas por padrões de 3 alarmes num universo de 12 alarmes diferentes. Portanto, para o sistema apresentado são possíveis 299 combinações diferentes de alarmes.

Apesar da simplicidade do sistema, pelo menos três questões interessantes podem ser discutidas com base nesta tabela. Seria realmente possível existir 299 possibilidades diferentes de padrões de alarmes para este processo? O segundo questionamento surge a partir do primeiro. Seria possível relacionar uma falha no processo a um determinado padrão de alarme? O terceiro questionamento surge a partir do segundo. A ordem de ativação dos alarmes na formação do padrão pode influenciar no diagnóstico da falha?

Tabela 27. Possibilidades de padrões de alarmes diferentes no processo.

Tipo de combinação	Combinações possíveis
$C_{0,12}$	1
$C_{1,12}$	12
$C_{2,12}$	66
$C_{3,12}$	220
Soma	299

A Tabela 28 apresenta a frequência de ocorrência dos alarmes para diferentes vazões de alimentação do reator ($q = 1$ l/min, $q = 11$ l/min *etc*). Observa-se que o

somatório em cada coluna obrigatoriamente deve ser igual a 100% e que para determinadas vazões alguns alarmes não são ativados. É o caso, por exemplo, dos alarmes TALL e TcAH na vazão de 21 l/min. A Tabela 29 mostra os padrões de alarmes mais frequentes observados em cada faixa de vazão de alimentação do reator simulada. Nota-se que apenas cinco padrões de alarmes aparecem na planta por causa de perturbações nesta variável do processo, o que sugere que este evento gera um número de padrões de alarmes característico que permite o seu diagnóstico.

Tabela 28. Frequência de ocorrência dos alarmes para diferentes q.

Alarmes	q = 1	q = 11	q = 21	q = 31	q = 41	q = 51	q = 61	q = 71	q = 81	q = 91
CAAHH	0,21%	0,13%	0,10%	0,10%	0,16%	0,16%	0,23%	17,97%	18,05%	16,67%
CAAH	0,40%	0,25%	0,20%	0,20%	0,32%	0,33%	0,46%	38,28%	38,35%	16,67%
CAAL	36,49%	22,22%	16,62%	16,67%	24,77%	24,81%	33,28%	0,00%	0,00%	0,00%
CAALL	36,35%	22,12%	16,53%	16,56%	24,53%	24,41%	0,00%	0,00%	0,00%	0,00%
TAHH	5,83%	5,15%	16,45%	16,34%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
TAH	7,20%	22,34%	16,71%	16,77%	24,93%	24,95%	32,74%	0,00%	0,00%	0,00%
TAL	0,24%	0,15%	0,11%	0,12%	0,18%	0,19%	0,27%	21,09%	21,05%	16,67%
TALL	0,01%	0,01%	0,00%	0,00%	0,01%	0,01%	0,01%	0,78%	0,75%	16,67%
TcAHH	5,83%	5,15%	16,45%	16,34%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
TcAH	7,20%	22,34%	16,71%	16,77%	24,93%	24,95%	32,74%	0,00%	0,00%	0,00%
TcAL	0,24%	0,15%	0,11%	0,12%	0,18%	0,19%	0,27%	21,09%	21,05%	16,67%
TcALL	0,01%	0,01%	0,00%	0,00%	0,01%	0,01%	0,01%	0,78%	0,75%	16,67%

Tabela 29. Padrões de alarmes observados para perturbações em q.

Padrões observados	q (l/min)
CAAL-CAALL-TAHH-TAH-TcAHH-TcAH	1 – 10
CAAL-CAALL-TAHH-TAH-TcAHH-TcAH	11 – 20
CAAL-CAALL-TAHH-TAH-TcAHH-TcAH	21 – 30
CAAL-CAALL-TAHH-TAH-TcAHH-TcAH	31 – 40
CAAL-CAALL-TAH-TcAH	41 – 50
CAAL-CAALL-TAH-TcAH	51 – 60
CAAL-TAH-TcAH	61 – 70
CAHHH-CAAH-TAL-TcAL	71 – 80
CAHHH-CAAH-TAL-TcAL	81 – 90
CAHHH-CAAH-TAL-TALL-TcAL-TcALL	91 – 100

A Tabela 30 apresenta a frequência de ocorrência dos alarmes para diferentes vazões do fluido refrigerante ($q = 1$ l/min, $q = 11$ l/min *etc*). Novamente, observa-se que para determinadas vazões alguns alarmes não são ativados na planta, sugerindo que os padrões de alarmes formados podem ser relacionados a eventos determinísticos. A Tabela 31 mostra os padrões de alarmes mais frequentes observados para cada q_c simulado. Verifica-se a existência de apenas quatro padrões de alarmes, sendo que os padrões CAAL-CAALL-TAHH-TAH-TcAHH-TcAH e CAAHH-CAAH-TAL-TcAL também ocorrem para perturbações em q .

Tabela 30. Frequência de ocorrência dos alarmes para diferentes q_c .

Alarmes	$q_c = 1$	$q_c = 11$	$q_c = 21$	$q_c = 31$	$q_c = 41$	$q_c = 51$	$q_c = 61$	$q_c = 71$
CAAHH	0,12%	0,12%	0,17%	0,34%	0,35%	17,65%	17,39%	17,02%
CAAH	0,26%	0,27%	0,40%	0,78%	0,81%	41,18%	40,58%	40,43%
CAAL	16,11%	16,05%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
CAALL	15,73%	13,78%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
TAHH	16,76%	17,20%	24,27%	0,00%	0,00%	0,00%	0,00%	0,00%
TAH	17,01%	17,56%	25,26%	49,06%	49,02%	0,00%	0,00%	0,00%
TAL	0,12%	0,13%	0,18%	0,37%	0,39%	19,85%	20,29%	20,57%
TALL	0,00%	0,01%	0,01%	0,01%	0,01%	0,74%	0,72%	0,71%
TcAHH	16,76%	17,20%	24,27%	0,00%	0,00%	0,00%	0,00%	0,00%
TcAH	17,01%	17,56%	25,26%	49,06%	49,02%	0,00%	0,00%	0,00%
TcAL	0,12%	0,13%	0,18%	0,37%	0,39%	19,85%	20,29%	20,57%
TcALL	0,00%	0,01%	0,01%	0,01%	0,01%	0,74%	0,72%	0,71%

Tabela 31. Padrões de alarmes observados para perturbações em q_c .

Padrões observados	q_c (l/min)
CAAL-CAALL-TAHH-TAH-TcAHH-TcAH	1 – 10
CAAL-CAALL-TAHH-TAH-TcAHH-TcAH	11 – 20
TAHH-TAH-TcAHH-TcAH	21 – 30
TAH-TcAH	31 – 40
TAH-TcAH	41 – 50
CAAHH-CAAH-TAL-TcAL	51 – 60
CAAHH-CAAH-TAL-TcAL	61 – 70
CAAHH-CAAH-TAL-TcAL	71 – 80

É interessante observar que nos dois casos simulados apenas 9 padrões de alarmes foram identificados, sendo que dois padrões ocorrem em ambas situações. Portanto, apenas sete padrões de alarmes diferentes podem ocorrer na planta por causa de perturbações na vazão de alimentação do reator e na vazão do fluido refrigerante. Este número é bem abaixo das 299 possibilidades calculadas pela Equação (36), destacando ainda mais o fato dos padrões de alarmes poderem ser relacionados a eventos determinísticos.

Dito isto, pode-se mapear o processo, seja ele um equipamento, sistema ou mesmo toda a unidade, a fim de sugerir o diagnóstico de falhas em função dos padrões de alarmes ativados na planta. No entanto, para que este diagnóstico seja preciso é necessário que os valores de *setpoint* dos alarmes estejam bem configurados e que as variáveis do processo sejam afetadas o mínimo possível pelos ruídos de medição.

4.4.2. Análise dos alarmes na presença de ruído de medição

No Capítulo 3 foi mostrado que a análise de correlação entre as variáveis do processo deve ser utilizada para justificar simplificações no sistema de alarmes. A presença de ruídos de medição, pelo menos a princípio, pode comprometer esta importante etapa, dificultando a simplificação do sistema de alarmes. Além disso, a presença de alarmes ruidosos aumentaria a frequência de ocorrência desses sinais, impactando diretamente na frequência observada dos padrões e, conseqüentemente, comprometendo a etapa de diagnóstico de falhas com base nas ocorrências dos padrões de alarmes. Portanto, um indicador de qualidade que permita aferir a presença de alarmes ruidosos pode ser uma importante ferramenta para melhorar o desempenho dos sistemas de alarmes em plantas industriais.

As Figuras 70 (a) e (b) mostram os mapas de cores obtidos a partir dos coeficientes de correlação calculados conforme Equação (11). A Figura 70 (a) mostra o resultado obtido para o caso de operação normal do reator e sem presença de ruído de medição. A Figura 70 (b) mostra a resposta do processo, também para o caso de operação normal, mas com ruído de medição associado à variável T_c . Observa-se que a presença de ruído, ainda que apenas em uma variável do processo, alterou o mapa de cores enfraquecendo as correlações entre as variáveis. O que não significa dizer que não existe correlação entre elas, conforme já mencionado neste trabalho.

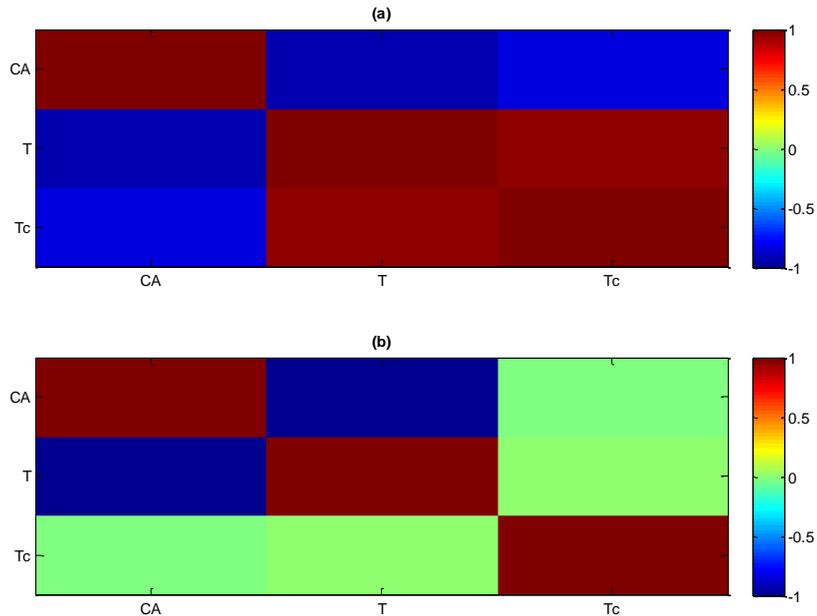


Figura 70. Influência do ruído de medição nas correlações (a) sem presença de ruído e (b) com presença de ruído.

A Figura 71 apresenta o algoritmo implementado em VBA-Excel® para identificar a presença de alarmes ruidosos para diferentes valores de T_c , com presença de ruído de medição, e *setpoint* de alarme fixo em 346,50 K. Na coluna “Medições” foram inseridos os valores de T_c obtidos das simulações realizadas no MATLAB®. Na coluna “Setpoint” foi informado o ponto de atuação do alarme e o tipo (alta ou baixa). Na coluna “Alarm” são apresentados os estados do alarme (1-ativado; 0-normal) calculados a partir das duas colunas anteriores. A coluna “RAT” (*register alarm time*) mostra o momento da ativação do alarme. A coluna “RNT” (*register normal time*) informa o momento da normalização do alarme. Na coluna “RL” (*run length*) indica a duração entre ativações de alarmes subsequentes e a coluna “Ψ” mostra, na forma decrescente, o tempo de duração entre ativações de alarmes subsequentes. O algoritmo foi desenvolvido para tempos de amostragem igual a 1 segundo o que significa dizer que, a unidade de tempo de “Ψ” também é em segundos.

A Figura 72 mostra o resultado obtido com o algoritmo para os mesmos valores de temperatura do fluido refrigerante apresentados anteriormente, porém com *setpoint* de alarme fixo no valor de 352 K. Observa-se que, diferentemente do caso anterior, nos 12 primeiros segundos de amostragem a variável do processo encontra-se abaixo do valor do *setpoint* de alarme, resultando num “RL” de 1 segundo e um valor de “Ψ” médio de

2,3 segundos. Ao comparar este resultado com o resultado da Figura 71 ($\Psi = 2.521$), parece intuitivo que quanto maior o valor de “ Ψ ”, mais demorado é o tempo entre ativações subsequentes do alarme e, pelo menos em tese, haverá mais tempo disponível para o diagnóstico do evento.

5	Medições	Setpoint	Alarm	RAT	RNT	RL	Ψ
6	351.00	346.50	0		0		2521
7	351.00	346.50	0		1		
8	349.57	346.50	0		2		
9	348.33	346.50	0		3		
10	350.13	346.50	0		4		
11	350.29	346.50	0		5		
12	348.85	346.50	0		6		
13	351.19	346.50	0		7		
14	351.19	346.50	0		8		
15	349.96	346.50	0		9		
16	350.33	346.50	0		10		
17	350.17	346.50	0		11		
18	349.81	346.50	0		12		

Figura 71. Algoritmo implementado em VBA-Excel® para identificar a presença de alarmes ruidosos na presença de *setpoint* de 346,50 K.

5	Medições	Setpoint	Alarm	RAT	RNT	RL	Ψ
6	351.00	352.00	1	0		0	4
7	351.00	352.00	1	1		1	3
8	349.57	352.00	1	2		1	3
9	348.33	352.00	1	3		1	2
10	350.13	352.00	1	4		1	2
11	350.29	352.00	1	5		1	2
12	348.85	352.00	1	6		1	2
13	351.19	352.00	1	7		1	2
14	351.19	352.00	1	8		1	2
15	349.96	352.00	1	9		1	2
16	350.33	352.00	1	10		1	2
17	350.17	352.00	1	11		1	2
18	349.81	352.00	1	12		1	2

Figura 72. Algoritmo implementado em VBA-Excel® para identificar a presença de alarmes ruidosos na presença de *setpoint* de 352 K.

As Figuras 73 (a) e 74 (a) apresentam o comportamento dinâmico do alarme na presença de *setpoint* de 346,50 K e 352 K, respectivamente, enquanto que as Figuras 73 (b) e 74 (b) mostram a distribuição de “ Ψ ” nas duas situações. Nota-se que a alternância frequência entre os estados ativado e normal do alarme provoca um gráfico mais denso, refletindo em uma distribuição de “ Ψ ” próxima a curva exponencial. Este resultado parece evidenciar mais uma vez que as ocorrências de alarmes discutidas no estudo de caso real apresentado neste trabalho são oriundas de alarmes ruidosos.

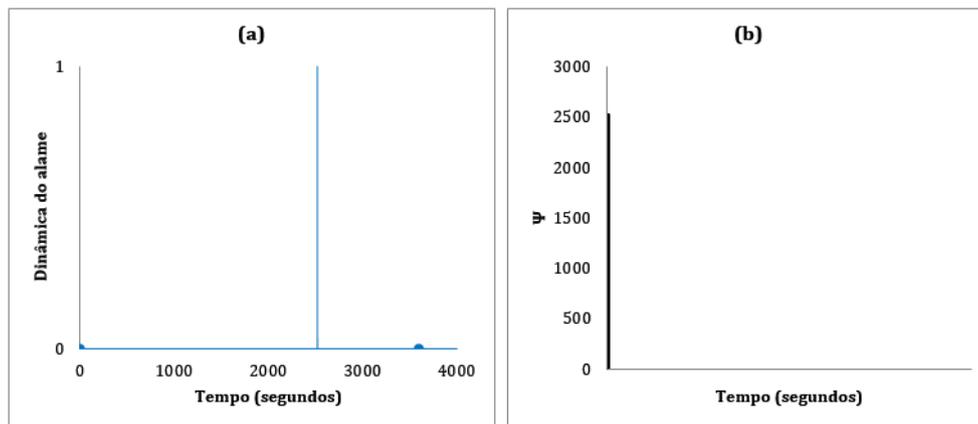


Figura 73. Comportamento dinâmico do sinal do alarme (a) e tempo de duração entre ativações de alarmes subsequentes (b) na presença de *setpoint* de 346,50 K.

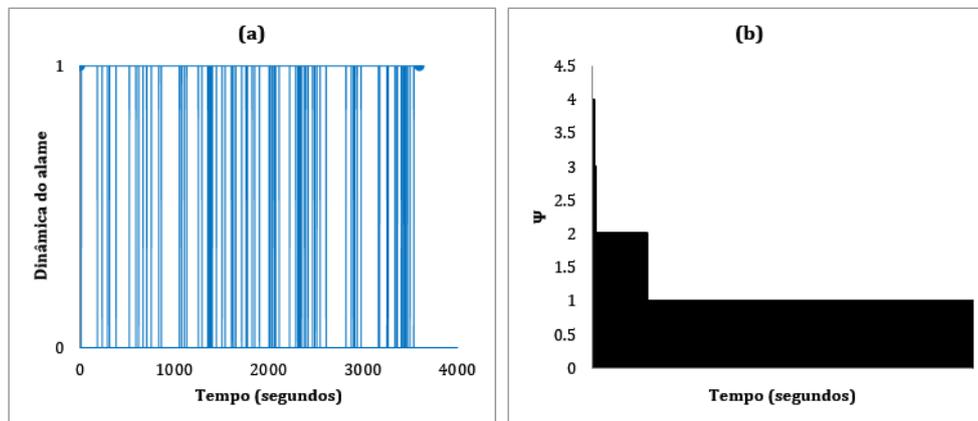


Figura 74. Comportamento dinâmico do sinal do alarme (a) e tempo de duração entre ativações de alarmes subsequentes (b) na presença de *setpoint* de 352 K.

4.5. Considerações Finais

Este capítulo apresentou como é possível desenvolver uma ampla linha de pesquisa envolvendo gerenciamento de alarmes e Engenharia Química. A metodologia aqui apresentada mostrou resultados bastante interessantes, mesmo diante de um modelo relativamente simples e de fácil entendimento. Conforme discutido, variáveis de processo correlacionadas não necessariamente resultam em alarmes correlacionados. Isto porque a presença de ruído nas variáveis de processo pode comprometer a identificação de correlações, tanto nos sinais de alarmes, quanto nas próprias variáveis de processo. Neste sentido, foi proposto um algoritmo em VBA-EXCEL® para identificar rapidamente a presença de alarmes ruidosos. Na sequência do capítulo foi realizado um estudo detalhado sobre a dinâmica dos padrões com base em um modelo simulado em MATLAB® de um reator CSTR com presença de reação exotérmica e não-linearidades. Por combinação, teoricamente, a depender do número de alarmes configurados no sistema, um número muito grande de possibilidades de padrões podem ocorrer. No entanto, na prática, apenas alguns poucos padrões estão associados a perturbações no processo. Portanto, o monitoramento dos padrões de alarmes, em especial a ordem com que eles aparecem na planta, fornecem informação preciosa a ser utilizada para diagnosticar diferentes cenários de falhas.

5. CONCLUSÕES E SUGESTÕES

Este capítulo apresenta algumas conclusões gerais sobre o tema detecção e diagnóstico de falhas em plantas industriais utilizando padrões de alarmes, as contribuições mais relevantes deste trabalho de tese e algumas sugestões para continuação de trabalhos futuros.

5.1. Conclusões

Neste trabalho, foram apresentados diversos problemas que ocorrem nos sistemas de alarmes das plantas industriais e que causam uma série de transtornos para a operação, como aumento do nível de estresse dos operadores e, num cenário mais crítico, banalização dos alarmes, comprometendo a segurança e qualidade das operações. A elevada taxa de ativação de alarmes, somada com os variados tipos de problemas (falsos alarmes, alarmes ruidosos, alarmes correlacionados, avalanches de alarmes) e com a falta de priorização destes sinais, permitiu o desenvolvimento de um protocolo de gerenciamento de alarmes com foco na resolução desses problemas. Conforme demonstrado, as práticas de gerenciamento de alarmes adotadas na planta (identificação, racionalização, gestão da mudança e monitoramento da eficácia) resultaram, não somente na redução das ocorrências de alarmes, mas também na qualidade dos dados de alarmes anunciados para os operadores. O protocolo de gerenciamento de alarmes desenvolvido neste trabalho teve eficácia comprovada através de um estudo de caso real aplicado em uma Unidade de Processamento de Gás Natural (UPGN) com redução de mais de 50% do número de ocorrências de alarmes na planta.

O estudo de caso real também permitiu identificar que o uso da análise de correlação, análise de agrupamentos e análise de componentes principais, podem ser utilizadas para identificar relações importantes entre as variáveis de processo e com base neste resultado, propor a redução do número de alarmes a serem monitorados na planta. Esta constatação foi comprovada com a aplicação das técnicas na seção de óleo térmico e no sistema de refrigeração a propano. Os diversos exemplos discutidos mostraram que às correlações identificadas nas variáveis de processo não necessariamente foram iguais as correlações dos seus respectivos alarmes. Isto porque as dinâmicas envolvidas nas variáveis de processo são diferentes das dinâmicas envolvidas na geração dos sinais de alarmes, sendo que esta última depende tanto da parte de *hardware* (como as instalações do sistema de alarmes foram instaladas na planta), como de *software* (como os parâmetros utilizadas para a geração do sinal de alarmes foram configurados).

Padrões de alarmes trazem informações importantes sobre o comportamento do processo, de maneira que permitem não apenas informar o problema para os operadores, como também sugerir um diagnóstico prévio do problema. Contudo esta informação preciosa ainda é pouco explorada nas plantas industriais. Para comprovar esta ideia, o Capítulo 4 deste trabalho discutiu a formação estacionária e dinâmica dos padrões de alarmes em função da presença de falhas específicas no processo. O estudo foi realizado através de um estudo de caso simulado em ambiente MATLAB®. Apesar da análise estacionária, verificou-se que apesar de existirem diferentes possibilidades de formação de padrões de alarmes (em função da quantidade de variáveis monitoradas e dos tipos de alarmes configurados), poucos padrões são efetivamente capazes de ocorrer no processo, o que comprova seu caráter determinístico. Por fim, a análise dinâmica dos padrões de alarmes indicaram que a ordem na qual estes sinais aparecem no processo podem indicar a existência de um evento específico, reduzindo e simplificando a etapa de diagnóstico de falhas na planta.

5.2. Sugestões para Trabalhos Futuros

Ainda que um significativo esforço venha sendo direcionado para estudo das deficiências dos processos e dos sistemas de monitoramento, existem questões ainda não exploradas na literatura em relação ao tema de modelagem de processos usando apenas dados históricos registrados. A primeira exigência é a necessidade de dados em condição normal de operação para a geração de um modelo adequado. Existem alternativas robustas na literatura que reduzem ou eliminam o efeito de valores espúrios possivelmente presentes no conjunto de dados. Entretanto, em um contexto industrial, não existem garantias quanto à condição dos dados, uma vez que pode haver longos períodos do processo em condição de falha estável e desconhecida. Isto faz com que os modelos sejam estimados incorretamente, mesmo em uma abordagem robusta, arruinando assim todo o sistema de monitoramento. O desenvolvimento de alternativas para análise e resolução deste problema é fundamental para a aplicação de sistemas de monitoramento em um ambiente industrial. Os dados reais de alarmes utilizados neste trabalho foram analisados *off-line*, ou seja, os padrões de alarmes já estavam estabelecidos restando apenas interpretá-los. Uma alternativa interessante seria avaliar estes padrões em tempo real ou mesmo de forma antecipatória.

Já em relação a um ambiente acadêmico, há necessidade de ferramentas para análise estatística de dados de forma simples e intuitiva. As técnicas contidas neste

trabalho de tese são diretamente aplicáveis a outros processos e problemas. Contudo, muitas vezes os usuários não dominam linguagens de computador, havendo a necessidade de auxílio para a elaboração das análises necessárias. Assim, o desenvolvimento de interfaces gráficas e de aplicativos representa uma alternativa direta para este problema. O modelo apresentado neste trabalho não fez nenhum tipo de abordagem associando os padrões de alarmes com as diferentes estratégias de controle e parâmetros de sintonias. Espera-se que na presença de malhas de controle influencie nas dinâmicas dos sinais de alarmes, de maneira que outros padrões poderão ser formados. Neste cenário vale a pena buscar respostas para as seguintes perguntas: a estratégia de controle utilizadas influencia na formação dos padrões de alarmes? Ou, os parâmetros de sintonias poderiam interferir nas dinâmicas dos padrões? Ou, a presença de mais de uma malha de controle poderia afetar as ativações de alarmes? Ou ainda, como os valores dos *setpoints* de alarmes poderiam ser alterados dinamicamente em função da reconfiguração dos parâmetros de controle?

Por fim, sugere-se introduzir no sistema outros tipos e combinações de falhas para ampliar o campo de investigação e identificar outros padrões de alarmes. Durante as simulações realizadas neste trabalho a capacidade de troca térmica (UA) foi mantida constante, porém, isto não é necessariamente uma verdade absoluta. Sabe-se que problemas de incrustação, por exemplo, poderia afetar a troca térmica do reator. O que aconteceria se houvesse alterações na concentração do reagente na corrente de alimentação do reator? E se houvesse presença deste reagente no reator no início do processo? Neste trabalho também não foi realizado combinações entre as diferentes falhas testadas. Esta é uma questão bastante pertinente e que também merece certa atenção. Por exemplo, quais os padrões são esperados quando distúrbios na vazão de alimentação e na vazão do fluido de refrigeração ocorrem simultaneamente?

REFERÊNCIAS BIBLIOGRÁFICAS

ABDEL-AAL, H. K., AGGOUR, M., FAHIM, M. A. *Petroleum and Gas Field Processing*. 2^a ed. New York, Marcel Dekker, 2003.

AHMED, K., IZADI, I., CHEN, T., *et al.* “Similarity analysis of industrial alarm old data”. *IEEE Transactions on Automation Science and Engineering*, 2011.

ANDRADE, V. E., 2012. *Sistema de Detecção e Diagnóstico de Falhas em Sensores de um Compressor de Gás Natural Utilizando Lógica Fuzzy Tipo-2*. M.Sc. Universidade Federal da Bahia, Salvador, BRA|.

ANP (2010). *O Gás Natural Liquefeito no Brasil – Experiência da ANP na implantação dos projetos de importação de GNL*. Rio de Janeiro, ANP – Agência Nacional do Petróleo, Gás Natural e Bicomcombustíveis.

ARJOMANDI, R. K., SALAHSHOOR, K. “Development of an efficient alarm management package for an industrial process plant”. *Chinese Control and Decision Conference (CCDC)*, 2011.

ARZÉN, E. E. “High level graph chart for alarm filtering”. In: *IFAC World Congress*, San Francisco, 1996.

BOYER, S. A. (1999). *SCADA: Supervisory Control and Data Acquisition*, Instrument Society of America.

BRANSBY, M. L. “Best Practice in Alarm Management”. *Control of Railways - The Human Challenge*. Published by the IEE, Savoy Place, London WC2R OBL, UK, 2000.

BRANSBY, M. L., JENKINSON, J., “Survey of alarm systems in the chemical and power industries”, *HSE Research Report CRR 166*, 1998.

BURNELL, E., DICKEN, C. R., 1997. “Handling of repeating alarms”. In: *IEE Colloquium on Stemming the Alarm Flood*, pp. 12/1-12/4, London, June.

CAMPOS, M. C. M. M., TEIXEIRA, H. C. G. *Controle típicos de equipamentos e processos industriais*. 1ª ed. São Paulo, Editora Blucher, 2006.

CHANG, Y.J., KHAN, F., AHMED, S. “A risk-based approach to design warning system for processing facilities”. *Process Safety and Environmental Protection*. v.89, pp. 310–316, 2011.

CHIANG, L. H., RUSSEL, E. L., BRAATZ, R. D. *Fault detection and diagnosis in industrial systems*. 1ª. ed., Springer, London, UK, 2001.

COMON, P., “Independent component analysis, a new concept?” *Signal Processing*, v. 36, pp. 287-314, 1994.

CONTEC (2012). N-2595: *Critérios de Projeto, Operação e Manutenção de Sistemas Instrumentados de Segurança em Unidades Industriais*. Brasil, CONTEC – Comissão de Normalização Técnica.

DONG, D., McAVOY, T. J. “Nonlinear principal component analysis based on principal curves and neural networks”. *Computers & Chemical Engineering*, v. 20, n. 1, pp. 65-78, 1996.

DUNN, D. G., SANDS, N. P. “Alarm Systems Standards Important”. *Source InTech*, v. 52, pp.65, 2005.

EEMUA (2013). *Publication No 191: Alarm Systems a Guide to Design, Management and Procurement*. England, EEMUA – The Engineering Equipment and Materials Users Association.

EPE (2010). *Balanço Energético Nacional 2010: Ano base 2009*. Rio de Janeiro, EPE – Empresa de Pesquisa Energética.

FIGUEREDO., A. K. M., 2016. *Desenvolvimento de Metodologia de gerenciamento de Alarmes do Sistema de Tratamento de Água em Plataforma Offshore*. M.Sc. Universidade Federal do Rio de Janeiro, Rio de Janeiro, BRA.

FRANK, P. M., GARCIA, E. A., KOPPEN-SELIGER, B. “Modelling for fault detection and isolation versus modelling for control”. *Mathematics and Computers in Simulation*, Vol. 53, pp 259-271, 2000.

GERTLER, J. *Fault Detection and Diagnosis in Engineering Systems*. 1^a ed., New York, Marcel Dekker, 1998.

GHARIANI, A., TOGUYÉNI, A. K. A., CRAYE, E. “A Functional Graph Approach for Alarm Filtering and Fault Recovery for Automated Production Systems”. In: *Proceedings of the Sixth International Workshop on Discrete Event Systems*, 2002.

GPSA. *Gas Processors Suppliers Association*. 7^a ed., Oklahoma, Gas Processors Suppliers Association, 1998.

GROSDIDIER, P., PATRICK, C., HOLLIFIELD, B., SAMIR, K. “A Path Forward for DCS Alarm Management”. *Plant Automation Services Inc.*, v. 12, pp. 1-16, 2003.

GUM. *Evaluation of measurement data – Guide to the expression of uncertainty in measurement*, 1^a ed., Rio de Janeiro, JCGM, 2012.

HABIBI, E., HOLLIFIELD, B. “Alarm systems greatly affect offshore facilities amid high oil process”. *World Oil Magazine*, v. 227, n. 9. September 2006.

HSE (1997). Health & Safety Executive, “The explosion and fires at Texaco Refinery, Milford Haven, 24 July 1994”, HSE, 1997.

ISA (2009). *ANSI/ISA-18.2-2009*. ISA – International Society of Automation, Management of Alarm Systems for the Process Industries, North Carolina, 2009.

ISERMANN, R. “Supervision, fault-detection and fault-diagnosis methods”. *Control Engineering Practice*, v. 5, pp 639-652, 1997.

ISERMANN, R. *Fault-Diagnosis Systems. An Introduction from Fault Detection to Fault Tolerance*. 1^a ed., Germany, Springer, 2006.

IZADI, I., SHAH, S. L., SHOOK, D. S., *et al.* "Optimal alarm design". In: *Proceedings of the 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, pp.651–656, June, 2009a.

IZADI, I., SHAH, S. L., SHOOK, D. S., *et al.* "A framework for optimal design of alarm systems". In: *7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, pp. 651-656, 2009b.

IZADI, I., SHAH, S. L., SHOOK, D. S., *et al.* "An introduction to alarm analysis and design." In: *7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, pp. 645-650, 2009c.

KIDNAY. A., PARRISH. W. R. *Fundamentals of Natural Gas Processing*. 1^a ed., Oxford, Elsevier, 2006.

KONDAVEETI, S., IZADI, I., SHAH, S., *et al.* "Graphical representation of industrial alarm data". In: *11th IFAC/IFIP/IFORS/IEA Symposium on Analysis, Design and Evaluation of Human-Machine Systems*, vol. 11, no. 1, pp. 181-186, 2010a.

KONDAVEETI, S., IZADI, I., SHAH, S., *et al.* "Quantification of alarm chatter based on run length distributions". In: *49th IEEE Conference on Decision and Control*, pp. 6809-6814, 2010b.

KONDAVEETI, SANDEEP REDDY., 2012, *Advanced Analysis and Redesign of Industrial Alarm Systems*. Ph.D. University of Alberta, Edmonton, USA.

KRAMER, M. A., "Nonlinear principal component analysis using autoassociative neural networks". *AICHE Journal*, v. 37, n. 2, pp. 233-243, Feb. 1991.

KU, W., STORER, R. H., GEORGAKIS, C., "Disturbance detection and isolation by dynamic principal component analysis". *Chemometrics and Intelligent Laboratory Systems*, v. 30, pp. 179-196, 1995.

LAI, X., TORP, H. “Interpolation methods for time-delay estimation using cross-correlation method for blood velocity measurement”. *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, v. 46, pp. 277-290, 1999.

LARSSON, J. E. “Simple Methods for Alarm Sanitation”. In: *IFAC Symposium on Artificial Intelligence in Real-Time Control AIRTC*, pp. 117–132, 2000.

LARSSON, J. E., JOSEPH D. Real-Time Root Cause Analysis for Complex Technical Systems. In: *Proceedings of the Joint 8th Annual IEEE Conference on Human Factors and Power Plants*, Monterey, California, 2007.

LEITÃO, G. B. P., 2008. *Algoritmos para Análise de Alarmes em Processos Petroquímicos*. M.Sc. Universidade Federal do Rio Grande do Norte, Natal, BRA.

LI, D., HU, J., WANG, H., Huang, W. “A distributed parallel alarm management strategy for alarm reduction in chemical plants”. *Journal of Process Control*, v. 34, pp117–125, 2015.

LYONS. W. C., PLISGA. G. J. *Standard Handbook of Petroleum & Natural Gas Engineering*. 2^a ed. Oxford, Elsevier, 2005.

MADOXX, R. N., JHON, H. E. *Gas Conditioning and Processing*. 3^a ed. Oklahoma, Campbell Petroleum Series, 1982.

MATHWORKS, 2010. MATLAB version 7.10.0 (R2010a). Natick, Massachusetts: The MathWorks Inc. <http://www.mathworks.com/products/matlab/>

MEYER, A. S., 2002. *Comparação de Coeficientes de Similaridade usados em Análise de Agrupamento com Dados de Marcadores Moleculares Dominantes*. M.Sc. Universidade de São Paulo, São Paulo, BRA.

MOKHATAB. S., POE. W. A., SPEIGHT. J. G. *Handbook of Natural Gas Transmission and Processign*. 1^a ed., Oxford, Elsevier, 2006.

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*. 5^a ed., New York, John Wiley & Sons, 2009.

O'BRIEN, L., WOLL, O. D. "Alarm Management Strategies". *ARC Strategies*. USA. November 2004.

PALMA, L. B., SILVA, R. N., COITO, F. V. "Metodologia híbrida de detecção e diagnóstico de falhas em tempo real". *Conferência Científica e Tecnológica em Engenharia*, Lisboa, pp 1-7, 2002.

PARIYANI, A., SEIDER, W. D., OKTEM, U. G., *et al.* "Dynamic Risk Analysis Using Alarm Databases to Improve Process Safety and Product Quality: Part I – Data Compaction". *American Institute of Chemical Engineers*, v. 58, 2011.

PINTO, J. C., LAGE, P. L. C. *Métodos Numéricos em Problemas de Engenharia Química*. 1^a ed., Rio de Janeiro, E-papers, 2001.

POWELL-PRICE, M., "The explosion and fires at the Texaco Refinery, 24 July 1994", *IChemE Loss Prevention Bulletin*, v.138, pp. 3-10, 1997.

QIN, S. J., "Statistical process monitoring: basics and beyond". *Journal of Chemometrics*, v. 17, pp. 480–502, 2003.

RIVERA, M. H. M., 2007. *Diagnóstico de Falhas em Sistemas a Eventos Discretos: Uma Proposta de Aplicação em Processos de Separação Óleo-Gás*. M.Sc. Universidade Federal do Rio de Janeiro, Rio de Janeiro, BRA.

ROTHENBERG, D. H., WILSON, C. "Best Practices in DCS Alarm Management". In: *13th Annual Joint ISA POWID/EPRI Controls and Instrumentation Conference*, 2003.

RUBINSTEIN, E. & MASON, J. F., "An analysis of Three Mile Island. The accident that shouldn't have happened. The technical blow-by-blow." *IEEE Spectrum*, pp. 33-42, 1979.

SARTORI, I., AMARO, C. A., DE SOUZA, M. B. J., *et al.* “Detecção, Diagnóstico e Correção de Falhas: Uma Proposição Consistente de Definições e Terminologias”. *Science & Engineering Journal*, v. 21, pp. 41–53, 2012.

SATUF., E. N, CAMPOS., M. C. M. M., SCHIRRU, R. “Filtrando e priorizando alarmes em tempo-real: sistema avançado de alarmes inteligentes (SAAI)”. In: *Anais do XX Congresso Brasileiro de Automática*, Belo Horizonte, Setembro, 2014.

SCHÖLKOPF, B., SMOLA, A. J., MÜLLER, K., “Nonlinear component analysis as a kernel eigenvalue problem”, *Neural Computation*, v. 10, pp. 1299-1399, 1998.

SCHWAAB. M., PINTO. J. C. C. *Análise de Dados Experimentais I. Fundamentos de Estatística e Estimação de Parâmetros*. 1ª ed., Rio de Janeiro, E-papers, 2007.

SEIDER. W. D. SEADER, J. D., LEWIN. D. R. *Product and Process Design Principles Synthesis, Analysis, and Evaluation*. 2ª ed., Israel, John Wiley & Sons, 2003.

SOARES, V. B., 2013. *Análise Crítica das Camadas de Proteção Exigidas pela NR 13 e sua Adequação para Processos de Extração Supercrítica*. M.Sc. Universidade Federal Rural do Rio de Janeiro, Rio de Janeiro, BRA.

SOARES., V. B., PINTO., J. C., SOUZA, M. B. “Estratégia de análise do comportamento de sinais de alarmes em plantas de processos”. *Alcoolbras*, Edição 140, 2013.

TEIXEIRA, A. C., 2000. *Detecção e diagnóstico de falhas em sistemas de processos químicos. Importância do conhecimento de estados intermediários de processos dinâmicos. Desenvolvimento de uma metodologia baseada em redes neurais*. D.Sc. Universidade Campinas, São Paulo, BRA.

TIPPING, M.E., BISHOP, C.M., “Probabilistic principal component analysis”. *Journal of the Royal Statistical Society*, v. 61, pp. 611-622, 1999.

TIXIER, J., DUSSERRE, G., SALVI, O., *et al.* “Review of 62 risk analysis methodologies of industrial plants”. *Journal of Loss Prevention in the Process Industries*, v. 15, pp. 291-303, 2002.

VAZ, C. E. M., MAIA, J. L. P., SANTOS, W. G. *Tecnologia da Indústria do Gás Natural*. 1ª ed., São Paulo, Editora: Edgard Blucher, 2008.

VICINI, L. (2005), *Análise Multivariada da Teoria à Prática*. Universidade Federal de Santa, UFSM, Santa Maria.

VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; YIN, K., *et al.* “A review of process fault detection and diagnosis Part I: Quantitative model-based methods”. *Computers and Chemical Engineering*, v. 27, pp. 293-311, 2003a.

VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; KAVURI, S.N. “A review of process fault detection and diagnosis Part II: Qualitative model and search strategies”. *Computers and Chemical Engineering*, v. 27, p.313-326, 2003b.

VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; YIN, K., *et al.* “A review of process fault detection and diagnosis Part III: Process history based methods”. *Computers and Chemical Engineering*, v. 27, pp. 327-346, 2003c.

WANG, J., LI, H., HUANG, J., *et al.* “A data similarity based analysis to consequential alarms of industrial processes”. *Journal of Loss Prevention in the Process Industries*, v. 35, pp. 29-34, 2015.

WANG, X., KRUGER, U., IRWIN, G. W., “Process monitoring approach Using fast moving window PCA”. *Ind. Eng. Chem. Res.*, v. 44, pp. 5691-5702, 2005.

WILLSKY, A. S. “Survey of design methods for failure detection in dynamic systems”. *Automatic*, v. 12, pp. 601-611, 1976.

WOLD, S., “Exponentially weighted moving principal components analysis and projections to latent structures”. *Chemometrics and Intelligent Laboratory Systems*, v. 23, pp. 149-161, 1994.

YANG, F., SHAH, S.L., XIAO, D. “Correlation analysis of alarm data and alarm limit design for industrial processes”. In: *Proceedings of the 2010 American Control Conference, ACC 2010*

APÊNDICE

Apêndice 1. Dados Diários de Ativação de Alarmes na Planta

A Tabela 32 mostra a totalização do número de alarmes ativados na Unidade de Processamento de Gás Natural apresentada no Capítulo 3 deste trabalho. Os dados de alarmes foram coletados diariamente do Sistema Supervisório de Controle e Aquisição de Dados (SCADA) da unidade e representam três anos de investigação.

Tabela 32. Dados diários das ocorrências de alarmes na planta registrados durante o período de três anos.

Data	Nº ativações de alarmes
01/01/2013	5.770
02/01/2013	6.331
03/01/2013	3.881
04/01/2013	4.203
05/01/2013	2.832
06/01/2013	2.877
07/01/2013	2.804
08/01/2013	2.901
09/01/2013	3.119
10/01/2013	3.030
11/01/2013	2.438
12/01/2013	2.077
13/01/2013	4.986
14/01/2013	2.852
15/01/2013	3.135
16/01/2013	3.206
17/01/2013	4.604
18/01/2013	6.886
19/01/2013	3.742
20/01/2013	3.631
21/01/2013	3.440
22/01/2013	2.190
23/01/2013	2.503
24/01/2013	2.441

25/01/2013	2.462
26/01/2013	1.848
27/01/2013	2.960
28/01/2013	2.703
29/01/2013	2.207
30/01/2013	2.551
31/01/2013	2.307
01/02/2013	4.150
02/02/2013	2.428
03/02/2013	3.584
04/02/2013	2.813
05/02/2013	2.493
06/02/2013	3.851
07/02/2013	2.559
08/02/2013	2.032
09/02/2013	2.383
10/02/2013	2.161
11/02/2013	3.597
12/02/2013	3.956
13/02/2013	4.469
14/02/2013	1.834
15/02/2013	3.051
16/02/2013	3.317
17/02/2013	3.278
18/02/2013	3.344
19/02/2013	3.705
20/02/2013	2.559
21/02/2013	4.142
22/02/2013	2.680
23/02/2013	1.313
24/02/2013	1.538
25/02/2013	2.072
26/02/2013	3.327

27/02/2013	2.348
28/02/2013	2.845
01/03/2013	5.880
02/03/2013	9.564
03/03/2013	4.520
04/03/2013	4.519
05/03/2013	1.876
06/03/2013	2.875
07/03/2013	2.274
08/03/2013	2.606
09/03/2013	2.545
10/03/2013	2.759
11/03/2013	2.470
12/03/2013	1.464
13/03/2013	2.479
14/03/2013	2.770
15/03/2013	2.073
16/03/2013	1.691
17/03/2013	1.664
18/03/2013	1.580
19/03/2013	1.413
20/03/2013	1.271
21/03/2013	1.774
22/03/2013	1.603
23/03/2013	2.866
24/03/2013	1.610
25/03/2013	2.276
26/03/2013	2.726
27/03/2013	1.657
28/03/2013	1.016
29/03/2013	953
30/03/2013	1.221
31/03/2013	1.579

01/04/2013	1.266
02/04/2013	1.264
03/04/2013	937
04/04/2013	1.672
05/04/2013	1.375
06/04/2013	1.876
07/04/2013	718
08/04/2013	820
09/04/2013	1.232
10/04/2013	1.903
11/04/2013	1.606
12/04/2013	4.088
13/04/2013	6.693
14/04/2013	1.488
15/04/2013	3.486
16/04/2013	2.352
17/04/2013	2.274
18/04/2013	3.654
19/04/2013	6.535
20/04/2013	4.890
21/04/2013	6.441
22/04/2013	3.316
23/04/2013	5.273
24/04/2013	4.045
25/04/2013	5.171
26/04/2013	5.468
27/04/2013	7.361
28/04/2013	2.514
29/04/2013	3.690
30/04/2013	7.941
01/05/2013	5.739
02/05/2013	2.832
03/05/2013	3.274

04/05/2013	3.034
05/05/2013	2.242
06/05/2013	2.054
07/05/2013	2.023
08/05/2013	2.091
09/05/2013	2.004
10/05/2013	1.805
11/05/2013	1.368
12/05/2013	1.485
13/05/2013	1.495
14/05/2013	2.046
15/05/2013	3.367
16/05/2013	1.983
17/05/2013	2.470
18/05/2013	2.389
19/05/2013	2.757
20/05/2013	2.322
21/05/2013	2.116
22/05/2013	1.534
23/05/2013	1.478
24/05/2013	3.027
25/05/2013	5.888
26/05/2013	4.212
27/05/2013	1.704
28/05/2013	2.438
29/05/2013	2.357
30/05/2013	1.859
31/05/2013	2.734
01/06/2013	2.797
02/06/2013	2.099
03/06/2013	2.575
04/06/2013	9.189
05/06/2013	9.019

06/06/2013	9.448
07/06/2013	4.417
08/06/2013	3.122
09/06/2013	2.791
10/06/2013	2.617
11/06/2013	952
12/06/2013	926
13/06/2013	967
14/06/2013	2.269
15/06/2013	2.569
16/06/2013	4.727
17/06/2013	2.883
18/06/2013	3.239
19/06/2013	2.681
20/06/2013	3.492
21/06/2013	3.050
22/06/2013	3.839
23/06/2013	1.714
24/06/2013	1.462
25/06/2013	2.889
26/06/2013	2.837
27/06/2013	2.897
28/06/2013	2.489
29/06/2013	940
30/06/2013	1.309
01/07/2013	1.807
02/07/2013	2.697
03/07/2013	2.402
04/07/2013	1.178
05/07/2013	1.077
06/07/2013	1.416
07/07/2013	1.369
08/07/2013	1.559

09/07/2013	3.056
10/07/2013	3.564
11/07/2013	1.603
12/07/2013	2.927
13/07/2013	1.647
14/07/2013	1.595
15/07/2013	1.823
16/07/2013	2.191
17/07/2013	1.516
18/07/2013	1.744
19/07/2013	1.523
20/07/2013	1.223
21/07/2013	743
22/07/2013	1.949
23/07/2013	1.824
24/07/2013	1.917
25/07/2013	1.686
26/07/2013	1.269
27/07/2013	1.522
28/07/2013	1.378
29/07/2013	1.901
30/07/2013	1.345
31/07/2013	3.040
01/08/2013	1.315
02/08/2013	2.065
03/08/2013	1.659
04/08/2013	1.254
05/08/2013	1.747
06/08/2013	1.493
07/08/2013	1.959
08/08/2013	1.861
09/08/2013	2.570
10/08/2013	1.959

11/08/2013	2.359
12/08/2013	2.373
13/08/2013	3.475
14/08/2013	2.691
15/08/2013	1.903
16/08/2013	2.408
17/08/2013	1.800
18/08/2013	1.453
19/08/2013	1.311
20/08/2013	959
21/08/2013	1.172
22/08/2013	907
23/08/2013	1.425
24/08/2013	794
25/08/2013	1.438
26/08/2013	2.054
27/08/2013	3.342
28/08/2013	1.456
29/08/2013	1.613
30/08/2013	1.645
31/08/2013	2.396
01/09/2013	986
02/09/2013	918
03/09/2013	1.036
04/09/2013	1.085
05/09/2013	992
06/09/2013	791
07/09/2013	1.386
08/09/2013	1.991
09/09/2013	2.557
10/09/2013	2.191
11/09/2013	1.157
12/09/2013	1.525

13/09/2013	1.237
14/09/2013	1.314
15/09/2013	1.089
16/09/2013	2.853
17/09/2013	2.202
18/09/2013	1.502
19/09/2013	861
20/09/2013	1.479
21/09/2013	1.768
22/09/2013	1.298
23/09/2013	1.926
24/09/2013	1.807
25/09/2013	1.627
26/09/2013	1.257
27/09/2013	1.162
28/09/2013	1.088
29/09/2013	1.033
30/09/2013	1.558
01/10/2013	1.461
02/10/2013	1.219
03/10/2013	1.383
04/10/2013	1.666
05/10/2013	1.216
06/10/2013	1.601
07/10/2013	2.787
08/10/2013	831
09/10/2013	1.814
10/10/2013	859
11/10/2013	912
12/10/2013	1.036
13/10/2013	640
14/10/2013	814
15/10/2013	844

16/10/2013	1.189
17/10/2013	440
18/10/2013	1.008
19/10/2013	2.050
20/10/2013	2.409
21/10/2013	2.015
22/10/2013	2.605
23/10/2013	2.010
24/10/2013	2.339
25/10/2013	1.603
26/10/2013	777
27/10/2013	573
28/10/2013	970
29/10/2013	1.287
30/10/2013	812
31/10/2013	1.149
01/11/2013	1.393
02/11/2013	1.235
03/11/2013	1.010
04/11/2013	1.667
05/11/2013	908
06/11/2013	1.136
07/11/2013	995
08/11/2013	1.157
09/11/2013	1.417
10/11/2013	1.567
11/11/2013	656
12/11/2013	1.436
13/11/2013	1.791
14/11/2013	913
15/11/2013	1.656
16/11/2013	777
17/11/2013	1.429

18/11/2013	1.476
19/11/2013	804
20/11/2013	673
21/11/2013	904
22/11/2013	1.682
23/11/2013	581
24/11/2013	1.358
25/11/2013	1.520
26/11/2013	1.756
27/11/2013	1.373
28/11/2013	1.861
29/11/2013	1.903
30/11/2013	1.972
01/12/2013	837
02/12/2013	1.394
03/12/2013	1.306
04/12/2013	1.303
05/12/2013	1.965
06/12/2013	1.958
07/12/2013	1.225
08/12/2013	1.531
09/12/2013	1.292
10/12/2013	1.159
11/12/2013	1.452
12/12/2013	1.596
13/12/2013	994
14/12/2013	937
15/12/2013	3.095
16/12/2013	1.588
17/12/2013	1.022
18/12/2013	4.979
19/12/2013	8.377
20/12/2013	5.678

21/12/2013	1.535
22/12/2013	1.459
23/12/2013	1.810
24/12/2013	1.029
25/12/2013	3.478
26/12/2013	3.227
27/12/2013	1.849
28/12/2013	1.730
29/12/2013	2.791
30/12/2013	1.255
31/12/2013	1.733
01/01/2014	3.772
02/01/2014	6.805
03/01/2014	6.515
04/01/2014	5.035
05/01/2014	5.307
06/01/2014	2.399
07/01/2014	913
08/01/2014	1.190
09/01/2014	2.095
10/01/2014	4.394
11/01/2014	1.931
12/01/2014	2.869
13/01/2014	2.774
14/01/2014	3.427
15/01/2014	2.042
16/01/2014	2.377
17/01/2014	1.985
18/01/2014	1.219
19/01/2014	1.291
20/01/2014	1.405
21/01/2014	2.282
22/01/2014	2.115

23/01/2014	1.747
24/01/2014	2.596
25/01/2014	3.451
26/01/2014	2.064
27/01/2014	5.648
28/01/2014	3.152
29/01/2014	2.269
30/01/2014	2.247
31/01/2014	3.982
01/02/2014	3.491
02/02/2014	1.336
03/02/2014	1.394
04/02/2014	1.049
05/02/2014	1.807
06/02/2014	1.580
07/02/2014	1.590
08/02/2014	853
09/02/2014	930
10/02/2014	1.428
11/02/2014	9.148
12/02/2014	4.503
13/02/2014	2.410
14/02/2014	948
15/02/2014	2.010
16/02/2014	1.302
17/02/2014	1.574
18/02/2014	997
19/02/2014	1.008
20/02/2014	703
21/02/2014	1.160
22/02/2014	723
23/02/2014	736
24/02/2014	1.655

25/02/2014	952
26/02/2014	897
27/02/2014	2.127
28/02/2014	1.678
01/03/2014	2.267
02/03/2014	1.214
03/03/2014	864
04/03/2014	769
05/03/2014	2.210
06/03/2014	1.071
07/03/2014	1.013
08/03/2014	2.392
09/03/2014	1.144
10/03/2014	1.494
11/03/2014	1.373
12/03/2014	1.380
13/03/2014	1.029
14/03/2014	869
15/03/2014	755
16/03/2014	861
17/03/2014	689
18/03/2014	851
19/03/2014	1.513
20/03/2014	1.766
21/03/2014	2.725
22/03/2014	1.340
23/03/2014	1.013
24/03/2014	1.548
25/03/2014	1.609
26/03/2014	1.508
27/03/2014	2.267
28/03/2014	2.414
29/03/2014	2.984

30/03/2014	1.053
31/03/2014	1.185
01/04/2014	1.618
02/04/2014	1.917
03/04/2014	2.392
04/04/2014	3.332
05/04/2014	2.128
06/04/2014	1.631
07/04/2014	5.155
08/04/2014	1.279
09/04/2014	2.553
10/04/2014	1.768
11/04/2014	1.509
12/04/2014	1.838
13/04/2014	4.459
14/04/2014	1.844
15/04/2014	673
16/04/2014	1.116
17/04/2014	2.220
18/04/2014	1.710
19/04/2014	910
20/04/2014	1.521
21/04/2014	1.235
22/04/2014	1.074
23/04/2014	1.423
24/04/2014	1.764
25/04/2014	1.905
26/04/2014	1.210
27/04/2014	950
28/04/2014	1.334
29/04/2014	2.336
30/04/2014	2.646
01/05/2014	1.715

02/05/2014	1.518
03/05/2014	1.702
04/05/2014	918
05/05/2014	1.620
06/05/2014	3.354
07/05/2014	3.445
08/05/2014	2.296
09/05/2014	1.884
10/05/2014	863
11/05/2014	1.019
12/05/2014	1.207
13/05/2014	1.136
14/05/2014	1.218
15/05/2014	997
16/05/2014	847
17/05/2014	930
18/05/2014	877
19/05/2014	1.102
20/05/2014	1.176
21/05/2014	1.436
22/05/2014	914
23/05/2014	1.110
24/05/2014	819
25/05/2014	1.200
26/05/2014	1.102
27/05/2014	1.836
28/05/2014	1.228
29/05/2014	1.512
30/05/2014	2.542
31/05/2014	2.085
01/06/2014	736
02/06/2014	1.284
03/06/2014	1.187

04/06/2014	1.573
05/06/2014	1.141
06/06/2014	2.392
07/06/2014	1.135
08/06/2014	1.307
09/06/2014	1.416
10/06/2014	778
11/06/2014	1.682
12/06/2014	929
13/06/2014	903
14/06/2014	804
15/06/2014	479
16/06/2014	1.162
17/06/2014	1.447
18/06/2014	1.055
19/06/2014	1.230
20/06/2014	998
21/06/2014	779
22/06/2014	1.126
23/06/2014	1.171
24/06/2014	1.120
25/06/2014	1.159
26/06/2014	1.042
27/06/2014	1.068
28/06/2014	860
29/06/2014	1.351
30/06/2014	1.645
01/07/2014	1.475
02/07/2014	1.147
03/07/2014	915
04/07/2014	1.025
05/07/2014	1.052
06/07/2014	885

07/07/2014	1.232
08/07/2014	1.352
09/07/2014	1.606
10/07/2014	1.525
11/07/2014	1.095
12/07/2014	773
13/07/2014	1.306
14/07/2014	1.521
15/07/2014	1.371
16/07/2014	2.097
17/07/2014	1.091
18/07/2014	4.536
19/07/2014	6.148
20/07/2014	3.876
21/07/2014	2.277
22/07/2014	1.129
23/07/2014	1.395
24/07/2014	1.199
25/07/2014	1.547
26/07/2014	958
27/07/2014	2.159
28/07/2014	1.802
29/07/2014	2.178
30/07/2014	2.068
31/07/2014	3.337
01/08/2014	1.546
02/08/2014	1.567
03/08/2014	1.414
04/08/2014	2.668
05/08/2014	3.384
06/08/2014	1.180
07/08/2014	1.615
08/08/2014	2.020

09/08/2014	1.089
10/08/2014	644
11/08/2014	1.365
12/08/2014	1.351
13/08/2014	1.331
14/08/2014	1.235
15/08/2014	1.851
16/08/2014	1.437
17/08/2014	1.326
18/08/2014	1.548
19/08/2014	4.834
20/08/2014	4.705
21/08/2014	4.365
22/08/2014	1.640
23/08/2014	1.686
24/08/2014	1.244
25/08/2014	1.366
26/08/2014	1.998
27/08/2014	1.598
28/08/2014	1.012
29/08/2014	1.465
30/08/2014	899
31/08/2014	2.816
01/09/2014	2.023
02/09/2014	2.416
03/09/2014	2.097
04/09/2014	8.159
05/09/2014	2.485
06/09/2014	1.865
07/09/2014	1.540
08/09/2014	1.084
09/09/2014	1.180
10/09/2014	1.978

11/09/2014	1.456
12/09/2014	1.271
13/09/2014	1.451
14/09/2014	832
15/09/2014	1.098
16/09/2014	1.499
17/09/2014	1.688
18/09/2014	822
19/09/2014	859
20/09/2014	1.211
21/09/2014	1.197
22/09/2014	1.838
23/09/2014	1.697
24/09/2014	1.014
25/09/2014	912
26/09/2014	1.092
27/09/2014	929
28/09/2014	508
29/09/2014	550
30/09/2014	676
01/10/2014	793
02/10/2014	1.164
03/10/2014	975
04/10/2014	574
05/10/2014	716
06/10/2014	749
07/10/2014	803
08/10/2014	825
09/10/2014	865
10/10/2014	726
11/10/2014	858
12/10/2014	1.331
13/10/2014	956

14/10/2014	1.323
15/10/2014	1.147
16/10/2014	648
17/10/2014	1.170
18/10/2014	816
19/10/2014	974
20/10/2014	1.708
21/10/2014	3.016
22/10/2014	1.155
23/10/2014	1.496
24/10/2014	832
25/10/2014	1.787
26/10/2014	1.920
27/10/2014	895
28/10/2014	763
29/10/2014	1.049
30/10/2014	1.258
31/10/2014	1.972
01/11/2014	1.532
02/11/2014	781
03/11/2014	1.898
04/11/2014	1.028
05/11/2014	725
06/11/2014	592
07/11/2014	727
08/11/2014	738
09/11/2014	756
10/11/2014	1.357
11/11/2014	1.302
12/11/2014	1.031
13/11/2014	939
14/11/2014	1.108
15/11/2014	1.968

16/11/2014	1.820
17/11/2014	1.319
18/11/2014	1.115
19/11/2014	1.232
20/11/2014	806
21/11/2014	755
22/11/2014	636
23/11/2014	1.223
24/11/2014	925
25/11/2014	1.028
26/11/2014	1.142
27/11/2014	1.340
28/11/2014	1.131
29/11/2014	1.513
30/11/2014	1.338
01/12/2014	2.113
02/12/2014	921
03/12/2014	1.283
04/12/2014	759
05/12/2014	627
06/12/2014	386
07/12/2014	461
08/12/2014	1.171
09/12/2014	834
10/12/2014	1.709
11/12/2014	1.245
12/12/2014	568
13/12/2014	491
14/12/2014	472
15/12/2014	1.164
16/12/2014	1.472
17/12/2014	749
18/12/2014	999

19/12/2014	1.139
20/12/2014	702
21/12/2014	812
22/12/2014	1.199
23/12/2014	1.106
24/12/2014	1.019
25/12/2014	663
26/12/2014	800
27/12/2014	609
28/12/2014	739
29/12/2014	1.142
30/12/2014	1.088
31/12/2014	1.747
01/01/2015	940
02/01/2015	1.033
03/01/2015	835
04/01/2015	669
05/01/2015	911
06/01/2015	819
07/01/2015	810
08/01/2015	693
09/01/2015	813
10/01/2015	832
11/01/2015	616
12/01/2015	805
13/01/2015	785
14/01/2015	698
15/01/2015	1.061
16/01/2015	1.024
17/01/2015	822
18/01/2015	1.161
19/01/2015	1.002
20/01/2015	970

21/01/2015	878
22/01/2015	726
23/01/2015	2.408
24/01/2015	850
25/01/2015	1.321
26/01/2015	1.409
27/01/2015	1.426
28/01/2015	1.418
29/01/2015	2.744
30/01/2015	1.446
31/01/2015	1.098
01/02/2015	857
02/02/2015	1.208
03/02/2015	814
04/02/2015	875
05/02/2015	1.309
06/02/2015	674
07/02/2015	1.302
08/02/2015	986
09/02/2015	750
10/02/2015	826
11/02/2015	694
12/02/2015	809
13/02/2015	1.872
14/02/2015	1.170
15/02/2015	1.436
16/02/2015	1.134
17/02/2015	810
18/02/2015	809
19/02/2015	723
20/02/2015	612
21/02/2015	1.098
22/02/2015	1.014

23/02/2015	1.769
24/02/2015	1.614
25/02/2015	1.978
26/02/2015	2.411
27/02/2015	2.146
28/02/2015	793
01/03/2015	624
02/03/2015	815
03/03/2015	903
04/03/2015	815
05/03/2015	1.192
06/03/2015	755
07/03/2015	743
08/03/2015	754
09/03/2015	1.505
10/03/2015	1.425
11/03/2015	1.185
12/03/2015	1.035
13/03/2015	666
14/03/2015	1.371
15/03/2015	1.372
16/03/2015	1.497
17/03/2015	736
18/03/2015	1.161
19/03/2015	844
20/03/2015	963
21/03/2015	761
22/03/2015	779
23/03/2015	924
24/03/2015	1.249
25/03/2015	1.726
26/03/2015	2.076
27/03/2015	1.309

28/03/2015	969
29/03/2015	869
30/03/2015	1.462
31/03/2015	1.271
01/04/2015	2.161
02/04/2015	1.400
03/04/2015	635
04/04/2015	1.090
05/04/2015	1.092
06/04/2015	1.046
07/04/2015	1.176
08/04/2015	896
09/04/2015	904
10/04/2015	907
11/04/2015	894
12/04/2015	1.160
13/04/2015	2.254
14/04/2015	1.422
15/04/2015	1.666
16/04/2015	1.719
17/04/2015	1.375
18/04/2015	1.869
19/04/2015	931
20/04/2015	1.001
21/04/2015	843
22/04/2015	764
23/04/2015	839
24/04/2015	680
25/04/2015	815
26/04/2015	1.059
27/04/2015	858
28/04/2015	4.031
29/04/2015	2.181

30/04/2015	2.556
01/05/2015	1.158
02/05/2015	1.164
03/05/2015	2.217
04/05/2015	1.715
05/05/2015	845
06/05/2015	975
07/05/2015	1.061
08/05/2015	1.111
09/05/2015	1.283
10/05/2015	1.126
11/05/2015	2.274
12/05/2015	781
13/05/2015	1.067
14/05/2015	3.865
15/05/2015	2.779
16/05/2015	738
17/05/2015	1.949
18/05/2015	786
19/05/2015	1.330
20/05/2015	1.118
21/05/2015	1.493
22/05/2015	1.295
23/05/2015	2.026
24/05/2015	848
25/05/2015	796
26/05/2015	923
27/05/2015	980
28/05/2015	689
29/05/2015	1.850
30/05/2015	637
31/05/2015	673
01/06/2015	763

02/06/2015	1.314
03/06/2015	914
04/06/2015	1.142
05/06/2015	1.815
06/06/2015	910
07/06/2015	892
08/06/2015	609
09/06/2015	1.191
10/06/2015	1.581
11/06/2015	966
12/06/2015	805
13/06/2015	830
14/06/2015	958
15/06/2015	1.302
16/06/2015	780
17/06/2015	1.533
18/06/2015	1.407
19/06/2015	1.027
20/06/2015	1.725
21/06/2015	987
22/06/2015	1.485
23/06/2015	1.680
24/06/2015	1.103
25/06/2015	1.588
26/06/2015	1.832
27/06/2015	2.766
28/06/2015	1.979
29/06/2015	1.397
30/06/2015	1.388
01/07/2015	1.238
02/07/2015	1.005
03/07/2015	962
04/07/2015	926

05/07/2015	1.760
06/07/2015	841
07/07/2015	1.558
08/07/2015	1.899
09/07/2015	2.068
10/07/2015	1.814
11/07/2015	1.789
12/07/2015	1.603
13/07/2015	1.562
14/07/2015	1.511
15/07/2015	1.643
16/07/2015	1.684
17/07/2015	1.294
18/07/2015	1.502
19/07/2015	1.322
20/07/2015	2.045
21/07/2015	1.742
22/07/2015	1.335
23/07/2015	1.167
24/07/2015	626
25/07/2015	1.052
26/07/2015	1.056
27/07/2015	846
28/07/2015	1.093
29/07/2015	566
30/07/2015	1.010
31/07/2015	1.446
01/08/2015	1.156
02/08/2015	955
03/08/2015	951
04/08/2015	1.082
05/08/2015	1.015
06/08/2015	1.244

07/08/2015	1.231
08/08/2015	873
09/08/2015	1.105
10/08/2015	3.865
11/08/2015	3.669
12/08/2015	1.680
13/08/2015	796
14/08/2015	1.137
15/08/2015	1.514
16/08/2015	1.304
17/08/2015	920
18/08/2015	1.191
19/08/2015	856
20/08/2015	672
21/08/2015	892
22/08/2015	670
23/08/2015	718
24/08/2015	435
25/08/2015	1.055
26/08/2015	2.479
27/08/2015	1.302
28/08/2015	1.587
29/08/2015	2.286
30/08/2015	1.828
31/08/2015	1.822
01/09/2015	991
02/09/2015	1.260
03/09/2015	891
04/09/2015	1.318
05/09/2015	835
06/09/2015	536
07/09/2015	409
08/09/2015	569

09/09/2015	840
10/09/2015	977
11/09/2015	1.803
12/09/2015	1.844
13/09/2015	1.153
14/09/2015	1.029
15/09/2015	1.642
16/09/2015	1.582
17/09/2015	1.285
18/09/2015	1.061
19/09/2015	6.215
20/09/2015	973
21/09/2015	849
22/09/2015	919
23/09/2015	2.903
24/09/2015	892
25/09/2015	1.240
26/09/2015	1.336
27/09/2015	1.094
28/09/2015	912
29/09/2015	820
30/09/2015	822
01/10/2015	754
02/10/2015	1.337
03/10/2015	790
04/10/2015	648
05/10/2015	1.349
06/10/2015	950
07/10/2015	1.134
08/10/2015	682
09/10/2015	409
10/10/2015	655
11/10/2015	827

12/10/2015	346
13/10/2015	510
14/10/2015	568
15/10/2015	391
16/10/2015	2.351
17/10/2015	1.499
18/10/2015	918
19/10/2015	626
20/10/2015	380
21/10/2015	730
22/10/2015	642
23/10/2015	784
24/10/2015	278
25/10/2015	479
26/10/2015	606
27/10/2015	567
28/10/2015	651
29/10/2015	796
30/10/2015	1.102
31/10/2015	555
01/11/2015	552
02/11/2015	602
03/11/2015	894
04/11/2015	808
05/11/2015	2.604
06/11/2015	1.766
07/11/2015	1.969
08/11/2015	936
09/11/2015	1.313
10/11/2015	819
11/11/2015	641
12/11/2015	580
13/11/2015	820

14/11/2015	634
15/11/2015	521
16/11/2015	482
17/11/2015	673
18/11/2015	420
19/11/2015	513
20/11/2015	1.774
21/11/2015	1.037
22/11/2015	577
23/11/2015	756
24/11/2015	710
25/11/2015	662
26/11/2015	784
27/11/2015	578
28/11/2015	651
29/11/2015	666
30/11/2015	451
01/12/2015	1.095
02/12/2015	969
03/12/2015	813
04/12/2015	717
05/12/2015	1.038
06/12/2015	1.003
07/12/2015	1.827
08/12/2015	587
09/12/2015	496
10/12/2015	613
11/12/2015	474
12/12/2015	765
13/12/2015	2.067
14/12/2015	746
15/12/2015	631
16/12/2015	1.643

17/12/2015	857
18/12/2015	726
19/12/2015	716
20/12/2015	476
21/12/2015	669
22/12/2015	1.341
23/12/2015	767
24/12/2015	880
25/12/2015	682
26/12/2015	767
27/12/2015	482
28/12/2015	635
29/12/2015	724
30/12/2015	614
31/12/2015	677
Total	1.847.346

Apêndice 2. Código de Programação Implementado no MATLAB®

O código a seguir roda no *Command Window* pelo chamado “main.m”. Ele representa o arquivo principal, onde estão inseridas as condições iniciais do reator, as perturbações, o tempo de simulação, o método de resolução das EDOs, as rotinas para elaboração dos gráficos e a rotina para exportação dos resultados para o EXCEL®.

```

%=====
%Limpar Dados do Command Window
%=====
clear all;
close all;
clc;
tic;
disp('Programa inicializado');

%=====
%Inserir Condições Iniciais do Reator
%=====
global u

Ca_ss = 1.0;           %concentração inicial do reator (mol/l)
T_ss = 350;           %temperatura inicial do reator (K)
x0 = [Ca_ss;T_ss];   %vetor com as condições iniciais do reator
u_ss = 351;           %temperatura inicial da jaqueta (K)
u = u_ss;             %saída do processo

```

```

%=====
%Inserir Intervalo de Amostragem
%=====
tf = 1/60;          %tempo de amostragem (min)

%=====
%Dimensionar Vetor com Condições Iniciais
%=====
cool(1) = u_ss;    %temperatura inicial da jaqueta (K)
Ca(1) = Ca_ss;    %concentração inicial do reator (mol/l)
T(1) = T_ss;      %temperatura inicial do reator (K)
time(1) = 0;      %início do tempo de simulação (min)

%=====
%Resolver Equações Diferenciais pelo Método ODE45
%=====

for i = 2:3601     %intervalo que representa 1 hora de operação

%=====
%Perturbações do tipo degrau
%=====
%Sem Presença de Perturbação
if (i==0)
    u = 350;
end

%1° Perturbação em 10 minutos
if (i>=600)
    u = 360;
end

%2° Perturbação em 20 minutos
if (i>=1200)
    u = 370;
end

%3° Perturbação em 30 minutos
if (i>=1800)
    u = 380;
end

%=====
%Perturbações do tipo senoidal
%=====
alpha = 0.1;      %período

%Sem Presença de Perturbação
if (i==2)
    u = 350;
end

%3° Perturbação em 30 minutos
if (i>=600)
    u = (280 + 20*sin(i/20))*alpha + (1-alpha)*u;
end

```

```

%Sem Presença de Perturbação
if (i>2400)
    u = 298;
end

%=====
%Solução do modelo
%=====
opts=odeset('RelTol',1e-6,'AbsTol',1e-6);
[t,x] = ode45('cstr',[0 tf],x0,opts);

%=====
%Dimensionar Vetor com Condições de Saída
%=====
time(i) = time(i-1) + tf;    %tempo de amostragem (min)
cool(i) = u;                %temperatura da jaqueta (K)
Ca(i) = x(end,1);          %concentração no reator (mol/l)
T(i) = x(end,2);           %temperatura do reator (K)

%=====
%Informar a Condição Final do Processo
%=====
x0(1) = Ca(i);              %concentração no reator (mol/l)
x0(2) = T(i);              %temperatura no reator (K)

%=====
%Adicionar ruídos de medição nas variáveis de processo
%=====
%Concentração no reator
Ca(i) = Ca(i) + (randn(1)-0.5)*0.2;

%Temperatura no reator
T(i) = T(i) + (randn(1)-0.5)*0.2;

%Temperatura do fluido de refrigeração
cool(i) = cool(i) + (randn(1)-0.5)*0.2;

end

%=====
%Plotar figuras com as respostas do modelo
%=====
figure(1);
hold on
box on
grid off

subplot(3,1,1)
plot(time,cool,'b','LineWidth',2);
ylabel('\bfT_c (K)')

subplot(3,1,2)
plot(time,T,'r','LineWidth',2);
ylabel('\bfT (K)')

subplot(3,1,3)
plot(time,Ca,'k','LineWidth',2);
ylabel('\bfC_A (mol/l)')
xlabel('\bfTempo (min)')

```

```

%=====
%Chamar Rotina para Salvar os Resultados em .xls
%=====
%Nome da Planilha onde as Informações Serão Salvas
planilha='results.xls';

%Tempo (min)
string1 = {'Tempo (min)'};
dados1 = time';
sucesso1 = xlswrite(planilha,string1,'Plan1','A1');
sucesso2 = xlswrite(planilha,dados1,'Plan1','A2');
if sucesso1*sucesso2 == 1
    disp('Tempo exportado com sucesso')
end

%Concentração no Reator (mol/l)
string2 = {'CA(mol/l)'};
dados2 = Ca';
sucesso3 = xlswrite(planilha,string2,'Plan1','B1');
sucesso4 = xlswrite(planilha,dados2,'Plan1','B2');
if sucesso3*sucesso4 == 1
    disp('Concentração no reator exportada com sucesso')
end

%Temperatura no Reator
string3 = {'T(K)'};
dados3 = T';
sucesso5 = xlswrite(planilha,string3,'Plan1','C1');
sucesso6 = xlswrite(planilha,dados3,'Plan1','C2');
if sucesso5*sucesso6 == 1
    disp('Temperatura no reator exportada com sucesso')
end

%Temperatura na Jaqueta (k)
string4 = {'Tc(K)'};
dados4 = cool';
sucesso7 = xlswrite(planilha,string4,'Plan1','D1');
sucesso8 = xlswrite(planilha,dados4,'Plan1','D2');
if sucesso7*sucesso8 == 1
    disp('Temperatura na jaqueta exportada com sucesso')
end

%=====
%Contar o tempo de simulação
%=====
tempo=toc;
fprintf('Programa finalizado em: %f segundos.\n\n',tempo);

```

O código a seguir não roda diretamente no *Command Window*, mas sempre é acionado automaticamente quando o código é acessado. Nele estão inseridos os parâmetros fixos e variáveis do modelo, bem como as EDOs originárias dos balanços de massa e de energia.

```
function xdot=cstr(t,x)
```

```

global u q qc V rho rhoc Cp Cpc mdelH EoverR k0 UA Caf T0

%=====
%Estados (2):
%=====
Ca = x(1,1); %concentração de A no reator (mol/l)
T = x(2,1); %temperatura no reator (K)

%=====
%Parâmetros Fixos do Modelo
%=====
V = 100; %volume do reator (l)
k0 = 7.2e10; %constante da taxa de reação(min-1)
EoverR = 1e4; %energia de ativação para R (K)
T0 = 350; %temperatura da corrente de alimentação (K)
Tc0 = u; %temperatura do fluido refrigerante (K)
mdelH = -2e5; %entalpia da reação (cal/mol)
Cp = 1.0; %calor específico do meio reacional (cal/g.K)
Cpc = 1.0; %calor calorífero do fluido de refrigeração (cal/g.K)
rho = 1e3; %densidade do meio reacional (g/l)
rhoc = 1e3; %densidade do fluido de refrigeração (g/l)

%=====
%Parâmetros Variáveis do Modelo
%=====
q = 100; %vazão da corrente de alimentação (l/min)
qc = 80; %vazão do fluido de refrigeração (l/min)
Caf = 1.0; %concentração da corrente de alimentação (mol/l)
UA = 7e5; %coeficiente de troca térmica (cal/min.K)

%=====
%Cálculo das Equações Diferenciais Ordinárias
%=====
%Equações Constitutivas:
k1 = k0*exp(-EoverR/T);

a1 = q/V;

a2 = -mdelH/(rho*Cp);

a3 = (rhoc*Cpc)/(rho*Cp*V);

a4 = -UA/(rhoc*Cpc);

%Balanço de Massa:
xdot(1,1) = a1*(Caf-Ca) - k1*Ca;

%Balanço de Energia:
xdot(2,1) = a1*(T0-T) + a2*k1*Ca + a3*qc*(1-exp(a4/qc))*(Tc0-T);

end

```